

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO  
CENTRO TECNOLÓGICO  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**Deteccção e diagnóstico de falhas em sistema de  
arrefecimento de motor Diesel ferroviário**

DISSERTAÇÃO DE MESTRADO

DANIEL AUGUSTO DO CARMO

Vitória-ES

2018

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO  
CENTRO TECNOLÓGICO  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**Detecção e diagnóstico de falhas em sistema de  
arrefecimento de motor Diesel ferroviário**

DANIEL AUGUSTO DO CARMO

Dissertação de Mestrado apresentada como  
requisito parcial para obtenção do título de  
Mestre em Engenharia Elétrica.

Orientador: Patrick Marques Ciarelli

Vitória-ES

2018

Dados Internacionais de Catalogação-na-publicação (CIP)  
(Biblioteca Setorial Tecnológica,  
Universidade Federal do Espírito Santo, ES, Brasil)

---

C287d Carmo, Daniel Augusto do, 1985-  
Detecção e diagnóstico de falhas em sistema de  
arrefecimento de motor Diesel ferroviário / Daniel Augusto do  
Carmo. – 2018.  
70 p. : il.

Orientador: Patrick Marques Ciarelli.  
Dissertação (Mestrado em Engenharia Elétrica) –  
Universidade Federal do Espírito Santo, Centro Tecnológico.

1. Motor diesel. 2. Localização de falhas (Engenharia).  
3. Classificadores (Linguística). I. Ciarelli, Patrick Marques.  
II. Universidade Federal do Espírito Santo. Centro Tecnológico.  
III. Título.

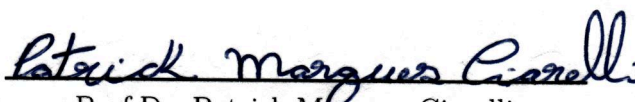
CDU: 621.3

DANIEL AUGUSTO DO CARMO

**Deteccção e diagnóstico de falhas em sistema de  
arrefecimento de motor Diesel ferroviário**

Dissertação de Mestrado apresentada como  
requisito parcial para obtenção do título de  
Mestre em Engenharia Elétrica.

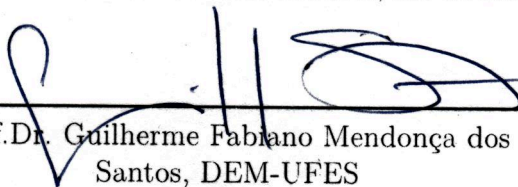
Trabalho aprovado. Vitória-ES, 06 de setembro de 2018:



Prof.Dr. Patrick Marques Ciarelli,  
DEL-UFES



Prof. Dr. Thomas Walter Rauber, DI-UFES



Prof.Dr. Guilherme Fabiano Mendonça dos  
Santos, DEM-UFES

Vitória-ES

2018

# Agradecimentos

Agradeço aos meus pais, que sempre souberam da importância do conhecimento, do trabalho e dos estudos. Ao professor doutor Celso José Munaro, que me orientou durante toda essa jornada. A minha namorada Priscilla, que estava do meu lado escutando minhas lamentações dos dias que se tornavam mais longos.

Ao pessoal do LCI, pelos momentos de descontração e de muitas risadas que fizeram a caminhada parecer menos íngreme, especialmente ao meu colega de dúvidas e discussões Uberdan Plácido. Ao professor doutor Patrick Marques Ciarelli pelo apoio e considerações importantes desse trabalho. Ao departamento de Engenharia Elétrica e a Universidade Federal do Espírito pela estrutura de ensino fornecida nesses anos.

A empresa VALE S.A e aos meus gestores, sempre me disponibilizando nos momentos em que precisavam do meu trabalho. Aos amigos do laboratório de eletrônica da oficina de locomotivas, me fornecendo importantes informações e conhecimentos. E todos aqueles que contribuíram indiretamente para que esse trabalho fosse concluído.

*"In a dark place we find ourselves, and a little more knowledge lights our way".*

*George Lucas*

# Resumo

Motores Diesel são usados em uma ampla gama de aplicações industriais, desde geradores de energia até motores mecânicos. A detecção de falhas incipientes é muito importante para a segurança e a redução de custos em qualquer uma dessas aplicações. Este trabalho apresenta duas abordagens para detecção de falhas no sistema de arrefecimento de um motor Diesel ferroviário e, em uma delas, também é realizado o diagnóstico. O motor estudado opera com diferentes rotações e potências que afetam as variáveis usadas em seu sistema de controle e de proteção. Foram coletados dados de operação normal e de falha de um motor Diesel real, através de um sistema desenvolvido para a aquisição dos dados. Na primeira abordagem propõe-se um classificador para identificar o ponto de operação a partir de medidas de rotação. Nesse caso, modelos baseados nos dados são criados para estimar a pressão interna do sistema de arrefecimento, e com elas gerar resíduos usados para a detecção da falha. Os múltiplos modos de operação requerem o uso de um classificador para selecionar um dos múltiplos modelos e normalização dos resíduos correspondentes. A aplicação dessa metodologia permitiu detectar a falha causada por vazamento de água com grande antecipação, sendo esta uma característica muito desejável em sistemas de detecção de falhas. A segunda abordagem faz o uso de classificadores do tipo kNN e redes neurais artificiais para a detecção e o diagnóstico de duas falhas: vazamento de água e redução da pressão no circuito de água. Características estatísticas dos sinais de velocidade do motor, pressão e temperatura de água são utilizadas pelos classificadores. Os classificadores foram avaliados pelo erro quadrático médio e os erros de classificação na matriz de confusão. Ambos os classificadores apresentaram bom desempenho para a detecção e o diagnóstico das duas falhas. A metodologia permite ampliar o número de falhas tratadas.

**Palavras-chave:** Motor Diesel. Detecção e diagnóstico de falhas. Classificadores. Ferrovia

# Abstract

Diesel engines are used in a wide range of industrial applications, from power generators to mechanical motors. The detection of incipient faults is very important for safety and cost reduction in any of these applications. This work presents two approaches for detecting failures in the cooling system of a railway diesel engine and, in one of them, the diagnosis is also made. The studied engine operates with different rotations and powers that affect the variables used in its control and protection system. Data from normal and faulty situations of a real diesel engine were collected through a system developed for data acquisition. In the first approach, a classifier is proposed to identify the operating point from rotation measurements. In this case, models based on the data are created to estimate the internal pressure of the cooling system, and with them generate residuals used for fault detection. The multiple modes of operation require the use of a classifier to select one of the multiple models and corresponding residual normalization. The application of this methodology allowed to detect the fault caused by water leakage with great anticipation, which is a very desirable feature in fault detection systems. The second approach uses kNN classifiers and artificial neural networks to detect and diagnose two types of failure: leakage of water and reduction of pressure in the water circuit. Statistical characteristics of the motor speed signals, pressure and water temperature are used by the classifiers. The classifiers were evaluated by the mean square error and the classification errors in the confusion matrix. Both classifiers presented good performance for the detection and diagnosis of the two faults. The methodology allows to increase the number of failures considered.

**Keywords:** Diesel engine. Fault detection and diagnosis. Classifiers. Railway.



# Lista de ilustrações

Figura 1 – Montagem básica de uma locomotiva Diesel-Elétrica. . . . .	15
Figura 2 – Causa de Reboques de uma ferrovia entre Jan/2016 a Jun/2018. . . . .	16
Figura 3 – Ciclo de um motor 4 tempos. . . . .	20
Figura 4 – Disposição dos principais componentes de um motor Diesel. . . . .	21
Figura 5 – Motor Diesel utilizado neste trabalho. . . . .	26
Figura 6 – Sistema de Arrefecimento da Locomotiva testada. . . . .	28
Figura 7 – Detecção e diagnóstico de falhas baseado em sinais. . . . .	29
Figura 8 – Esquema de processo de detecção e diagnóstico de falhas baseado em modelos do processo. . . . .	30
Figura 9 – Principais métodos de detecção de falhas baseadas em modelos do processo. <b>a</b> estimação de parâmetros, <b>b</b> estimação de estados, <b>c</b> equações de paridade. . . . .	32
Figura 10 – Esquema de diagnóstico de falhas através do uso de classificadores . . .	33
Figura 11 – Dados Interpolados. . . . .	44
Figura 12 – Sinais coletados em operação normal e com vazamento de água. . . . .	45
Figura 13 – Dispersão de pressão e temperatura sem classificação. . . . .	46
Figura 14 – Dados utilizados para treinamento e validação do classificador kNN. . .	47
Figura 15 – Classificação dos pontos de operação. . . . .	47
Figura 16 – Dados agrupados por ponto de operação. . . . .	48
Figura 17 – Comparação entre o coeficiente de Spearman e RMSE para regressão obtida via SVR no ponto de operação de 995 RPM. . . . .	49
Figura 18 – Comparativo entre o coeficiente de Spearman entre todas as técnicas de modelagem por ponto de operação. . . . .	49
Figura 19 – Comparativos entre os coeficientes de Spearman das técnicas empregadas. .	50
Figura 20 – Comparativos entre os erros (RMSE) das técnicas empregadas. . . . .	51
Figura 21 – Resíduos não normalizado e resíduos normalizados com limiares fixos. .	52
Figura 22 – Detecção de Vazamento na Carta de Soma Cumulativa. . . . .	53
Figura 23 – Valor da assimetria e sua variação com uma janela de 200 amostras. . .	54
Figura 24 – Média dos desempenhos do classificador <i>KNN</i> . . . . .	54
Figura 25 – Matriz de confusão do classificador kNN, dados de treinamento . . . . .	55
Figura 26 – Matriz de confusão do classificador kNN, dados de testes . . . . .	55
Figura 27 – Comparativo das médias dos desempenhos das redes neurais . . . . .	56
Figura 28 – Matriz de confusão do classificador ANN, dados de treinamento . . . . .	57
Figura 29 – Matriz de confusão do classificador ANN, dados de testes . . . . .	57
Figura 30 – Aplicação online do classificador: classes esperadas e as indicadas . . .	58
Figura 31 – Conversor RS232 para TTL 3.3V. . . . .	66

# Lista de tabelas

Tabela 1	–	Tabela de velocidade do motor e potência para tração da locomotiva. .	26
Tabela 2	–	Vantagens e desvantagens dos classificadores utilizados. . . . .	40
Tabela 3	–	Tabela comparativa entre o coeficiente de Spearman entre todas as técnicas de modelagem por ponto de operação. . . . .	50

# Lista de abreviaturas e siglas

BDC	Ponto morto inferior
TDC	Ponto morto superior
ECU	<i>Engine Control Unit</i>
TPU	<i>Time processing unit</i>
HP	<i>Horse Power</i>
DASH9	Locomotiva Diesel-Elétrica modelo DASH9-40BBW.
RPM	Rotações por minuto
WFMV	<i>Water Flow Main Valve</i>
FDI	<i>Fault detection isolation</i>
PCA	Análise de componetnes principais
kNN	k Vizinhos mais próximos
SVM	Máquinas de vetores de suporte
ANN	Redes neurais artificiais
RMSE	Raiz quadrada do erro quadrático médio
AIC	Critério de informação de Akaike
BIC	Critério de informação Bayesiana
$QV_N$	Número de verdadeiros negativos
$QV_P$	Número de verdadeiro positivos
$QF_N$	Número de falsos positivos
$QF_P$	Número de falsos negativos
$Pr_i$	Probabilidade da classe real
$Pe_i$	Probabilidade da classe estimada

# Lista de símbolos

$U$	Entradas
$Y$	Saídas
$S$	Sintomas
$r$	Resíduos
$x$	Estados
$\hat{x}$	Estados estimados
$\Theta$	Parâmetros
$\hat{\Theta}$	Parâmetros estimados
$G_P$	Função de transferência da planta
$G_M$	Função de transferência do modelo
$y_M$	Saídas estimadas do modelo
$k$	Número de vizinhos do classificador kNN

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>14</b>
<b>1.1</b>	<b>Objetivo Geral</b>	<b>17</b>
<b>1.2</b>	<b>Estrutura do Trabalho</b>	<b>18</b>
<b>2</b>	<b>DESCRIÇÃO DO MOTOR DIESEL</b>	<b>19</b>
<b>2.1</b>	<b>O motor Diesel</b>	<b>19</b>
<b>2.2</b>	<b>Subsistemas</b>	<b>20</b>
2.2.1	Sistema de Injeção	21
2.2.2	Sistema de Controle	22
2.2.3	Sistema de Admissão de Ar	22
2.2.4	Sistema de Lubrificação	22
2.2.5	Sistema de Arrefecimento	23
<b>2.3</b>	<b>Falhas comuns</b>	<b>23</b>
<b>2.4</b>	<b>Locomotiva e o Motor Diesel Ferroviário</b>	<b>24</b>
2.4.1	Locomotiva DASH9-40BBW	25
2.4.2	Sistema de arrefecimento da locomotiva DASH9-40BBW	26
<b>2.5</b>	<b>Revisão da literatura de métodos de detecção e diagnóstico aplicados a motores Diesel</b>	<b>27</b>
2.5.1	Detecção e diagnóstico de falhas baseados no conhecimento	27
2.5.2	Detecção de falhas por análise de sinais	28
2.5.3	Detecção e diagnóstico de falhas baseados em modelos do processo	29
2.5.4	Detecção e diagnósticos de falhas por classificadores	33
<b>3</b>	<b>METODOLOGIAS PROPOSTAS</b>	<b>36</b>
<b>3.1</b>	<b>Coleta dos dados</b>	<b>36</b>
<b>3.2</b>	<b>Detecção de falhas baseada em modelos do processo</b>	<b>37</b>
3.2.1	Detecção do ponto de operação	37
3.2.2	Modelos e geração de resíduos	38
3.2.3	Análise dos resíduos e detecção de falhas	39
<b>3.3</b>	<b>Detecção e diagnóstico de falhas com o uso de classificadores</b>	<b>40</b>
3.3.1	Características de entrada dos classificadores	40
3.3.2	Treinamento e testes dos classificadores	41
3.3.3	Classificador kNN	41
3.3.4	Classificador ANN	41
3.3.5	Métricas de desempenho de classificadores	41

<b>4</b>	<b>APLICAÇÃO E RESULTADOS</b>	<b>43</b>
<b>4.1</b>	<b>Coleta de Dados</b>	<b>43</b>
<b>4.2</b>	<b>Resultados via detecção baseada em modelos do processo</b>	<b>44</b>
4.2.1	Detecção dos pontos de operação	44
4.2.2	Seleção dos modelos	48
4.2.3	Detecção de falhas	50
<b>4.3</b>	<b>Resultados via classificadores</b>	<b>52</b>
4.3.1	Escolha das características	52
4.3.2	Classificador kNN	53
4.3.3	Classificador ANN	56
4.3.4	Aplicação online	58
<b>4.4</b>	<b>Comparação entre as abordagens</b>	<b>58</b>
<b>5</b>	<b>CONCLUSÕES</b>	<b>60</b>
	<b>REFERÊNCIAS</b>	<b>62</b>
	<b>APÊNDICE A – CIRCUITO ELETRÔNICO DE COLETA</b>	<b>66</b>
	<b>APÊNDICE B – CÓDIGO MATLAB PARA COLETA DE DADOS</b>	<b>67</b>
	<b>APÊNDICE C – CÓDIGO PYHTON PARA COLETA DE DADOS</b>	<b>69</b>

# 1 Introdução

Rudolf Diesel, em 27 de fevereiro de 1892, entrou com o pedido de patente para um novo tipo de motor de combustão interna e, em fevereiro do ano seguinte, lhe foi concedida sob o nome “Método de trabalho e de projetos para motores de combustão” (JOHNSON; MOLLENHAUER; TSCHÖKE, 2010). Essa é a data de nascimento de um dos motores mais versáteis já inventados, o motor Diesel. Popularmente conhecido como “motor a diesel”, isso devido ao combustível que também recebeu o sobrenome do seu inventor. Mas o motor pode receber vários tipos diferentes de óleo, bastando fazer ajustes de projeto.

Hoje, os motores Diesel são amplamente empregados na indústria em geral, devido a sua elevada eficiência térmica comparada aos outros motores de combustão interna. Isso contribui para a redução de custos operacionais das empresas. A confiabilidade desses motores é elevada e desde sua concepção já necessitam ser mais robustos, devido às elevadas taxas de compressão a que seus cilindros são submetidos durante o funcionamento, o que o torna mais pesado, um dos únicos pontos negativos desse motor.

As vantagens que podemos elencar são: tem eficiência térmica superior quando comparados a motores de ciclo Otto, produzindo a mesma quantidade de energia consumindo menos combustível; emitem menos dióxido de carbono que motores a gasolina, mesmo não usando biodiesel; os óleos combustíveis que podem ser usados nesse tipo de motor são mais seguros, pois são menos inflamáveis; não precisam de um sistema de ignição do combustível, reduzindo a possibilidade de falhas de partes internas responsáveis por essa função.

O número de aplicações é extensa, como os carros movidos a motores a diesel, os geradores de energia de aplicação comercial e industrial, os motores Diesel auxiliares dos motores Diesel de navios e, até mesmo com seu peso elevado, é possível encontrar aplicação na aviação desde os anos 30. A aplicação ferroviária teve início nos primeiros anos do século XX, com a primeira locomotiva tracionando em trechos na Suíça.


Atualmente, o mercado de cargas ferroviárias brasileiro e norte-americano é constituído basicamente de locomotivas híbridas Diesel-Elétricas. O motor Diesel é acoplado a um alternador e esse é responsável em gerar a energia elétrica para os motores de tração. Este trabalho tem como foco motores Diesel de aplicação ferroviária, essenciais nas locomotivas Diesel-elétricas.

Para o aumento da eficiência das locomotivas, além de melhorias construtivas da máquina, os controles de ambos os sistemas mecânico e elétrico vêm evoluindo. Cada vez mais sensores são instalados e mais informações podem ser extraídas da locomotiva, como falhas do motor. Usualmente, esses dados são utilizados somente para proteção da

máquina. Caso os valores das variáveis atinjam limites técnicos, alarmes são gerados.

Através dos índices da figura 1, pode-se explicar o funcionamento básico de uma locomotiva Diesel-elétrica. O maquinista da cabine (2) seleciona a potência que ele deseja adicionar ao trem, o sistema de controle do motor e elétrico verificam os estados dos outros sistemas da máquina e comandam o motor Diesel (4) e alternador (3), respectivamente, e em conjunto produzem a energia necessária aos motores de tração (1). Caso o motor chegue a uma determinada temperatura, os ventiladores (5) e radiadores (7) são acionados para que o calor produzido seja despejado para a atmosfera. Um item interessante a ser destacado é que o compressor da locomotiva (6) é responsável em abastecer os cilindros de freio não somente da locomotiva, mas como de todos os vagões do trem. Sem ele a composição ferroviária não freia adequadamente.

Figura 1 – Montagem básica de uma locomotiva Diesel-Elétrica.



Fonte: (EMD, 2010)

Caso o motor Diesel da locomotiva venha a falhar, todo o processo produtivo de uma ferrovia pode ser prejudicado, sendo necessário o reboque da locomotiva. O reboque é o evento em que uma segunda locomotiva é necessária para mover a locomotiva inoperante, e isso prejudica toda a circulação dos trens da ferrovia. Dependendo da localização do evento, pode-se levar dias para que o problema seja sanado por completo.


Fazer a detecção e diagnóstico antecipados de uma falha, não somente na locomotiva, mas em qualquer ativo que está sob a ferrovia se faz de alta valia, reduzindo ou até evitando os impactos indesejados. Um ponto importante ressaltado por (LEE; KAO; YANG, 2014), que é característica comum nas ferrovias, é a existência de frotas de equipamentos iguais operando em diversas condições diferentes. Dessa maneira, pode-se extrair características preditivas com maior facilidade, dada a quantidade de informação que pode ser extraída de uma frota.



Dentro da vasta gama de possibilidades de falhas no motor, a maioria das falhas causadoras de reboque da frota da ferrovia estudada são causadas por problemas elétricos. Essa característica se dá principalmente pela utilização de motores de tração compactos e com alta capacidade de carga. Os problemas mecânicos não deixam de impactar fortemente no processo da ferrovia, visto que problemas com o motor geram impactos maiores do que aqueles gerados por problemas elétricos.

A figura 2 apresenta um histórico de reboques, entre janeiro de 2016 e junho de 2018 de uma ferrovia que interliga os estados do Espírito Santo e Minas Gerais, no Brasil. Percebe-se, em destaque vermelho na figura, que o primeiro problema relacionado a motores encontra-se no sistema de arrefecimento. Ocorreram 16 reboques, desde então, causados por vazamento do fluido de arrefecimento, direcionando o objetivo geral do trabalho.

Figura 2 – Causa de Reboques de uma ferrovia entre Jan/2016 a Jun/2018.



Fonte: Própria

Reduzir o volume de falhas dos motores Diesel é garantir a sustentabilidade da organização que depende do seu bom funcionamento. Para que o motor Diesel funcione corretamente, todos os seus subsistemas devem estar funcionando corretamente. Um desses subsistemas é o de arrefecimento, e quando este falha, as chances da ocorrência de reboques são elevadas, impactando nos indicadores de desempenho da ferrovia. Fazendo a detecção e o diagnóstico de falhas desse sistema, antecipadamente, os impactos são reduzidos.

Atualmente, os processos de manutenção de locomotivas de forma geral é um processo reativo à falhas. Os planos de manutenção são desenhados para que componentes

sejam trocados com base no tempo de operação médio entre as falhas, aumentando os custos de manutenção. Na operação diária das locomotivas elas são inspecionadas visualmente, buscando sinais de possíveis problemas. Existem planos preditivos de manutenção por análise de vibração, óleo e termográfica, mas devido aos custos dos equipamentos esses são utilizados de forma *offline*.

Já foram publicados trabalhos tendo como objetivo a detecção de falhas em motores Diesel e de combustão interna, destacando os trabalhos de detecção de falhas usando modelos de sinal e processos do sistema de ar e combustão de motores Diesel (KIMMICH; SCHWARTE; ISERMANN, 2005), detecção de falhas em motores Diesel marítimos através de análises de resíduos (KHELIL et al., 2012), detecção de falhas no sistema de admissão de motores Diesel utilizando modelos paramétricos do motor (SCHWARTE; ISERMANN, 2002). Trabalhos como de Nyberg (1999) e Isermann (2016) fazem análise geral de técnicas, métodos e teorias aplicadas a diagnóstico de falhas em motores de combustão interna, com aplicações focadas nos sistemas de injeção, combustão e admissão de ar.

## 1.1 Objetivo Geral

O objetivo deste trabalho é detectar e diagnosticar falhas no sistema de arrefecimento de um motor Diesel ferroviário de forma antecipada ao sistema de detecção já existente, através dos mesmos sinais do sistema de controle do motor e utilizando duas abordagens baseadas em dados: detecção baseadas em modelos do processo e detecção e diagnóstico de falhas por meio do uso de classificadores.

### Objetivos específicos

Este trabalho tem como objetivos específicos:

- Aplicar método de detecção de falha baseado em modelos do sistema de arrefecimento do motor Diesel
- Antecipar a detecção de vazamento de água de arrefecimento do sistema;
- Avaliar classificadores na tarefa de detecção e diagnóstico de falhas no sistema de arrefecimento;
- Comparar os resultados das abordagens propostas.
- Desenvolver alternativas e rotinas que possibilitem o monitoramento online da locomotiva.

## 1.2 Estrutura do Trabalho

O trabalho está disposto da seguinte forma. No capítulo 2 é feita a introdução sobre o funcionamento de motores Diesel apresentando os papéis individuais de cada um dos seus subsistemas. Nessa seção também é feita a revisão bibliográfica dos métodos baseados em modelos e sobre a utilização de classificadores para detecção e diagnóstico de falhas em motores. No capítulo 3 é apresentada a metodologia que será aplicada para detecção e diagnóstico aplicada a um motor Diesel real de locomotivas. No capítulo 4 são apresentados os testes realizados com os dados coletados e no capítulo 5, as conclusões.

Resultados desta dissertação foram submetidos e aprovados para o congresso brasileiro de automática 2018 (CBA) com o trabalho: “Detecção de falhas baseada em dados em sistema de arrefecimento de motor Diesel” e para o *International Conference on Industry Applications 2018* (Induscon) com o trabalho: “Application of kNN and artificial neural network classifiers for fault detection and diagnosis in a diesel engine cooling system”.

## 2 Descrição do motor Diesel

Este capítulo apresenta características básicas de funcionamento de motores de combustão interna, dando ênfase ao motor Diesel. São apresentadas as causas mais comuns de falhas dos subsistemas dos motores Diesel e as especificidades de um motor Diesel ferroviário. Também é feita revisão bibliográfica de técnicas aplicadas à detecção e diagnóstico de falhas em motores, principalmente em motores Diesel.

### 2.1 O motor Diesel

Motores a combustão são motores em que a energia química é convertida em energia mecânica, resultado da combustão de uma mistura inflamável de gases e combustível (BASSHUYSEN; SCHÄFER, 2004). Os motores de combustão interna são máquinas em que essa energia é transformada pelo deslocamento de um ou mais pistões em câmaras fechadas e transferidas para um eixo girante.


Um motor de combustão interna apresenta uma ou mais câmaras de combustão, essas são chamadas de cilindros, dentro deles os pistões realizam um movimento retilíneo, que por sua vez estão conectadas a bielas que transferem seus movimentos para o eixo virabrequim.

Esses motores podem ser divididos em dois grandes grupos: de dois e quatro tempos. Os estágios são organizados da seguinte maneira: admissão, compressão, combustão e exaustão. Motores dois tempos completam os estágios em apenas uma revolução completa do eixo, enquanto que motores quatro tempos necessitam de duas voltas completas.

Na figura 3 é apresentado um esquema de funcionamento de um motor quatro tempos e de algumas das principais partes montadas aos cilindros do motor. Nesta figura destacam-se os estágios: a) Tempo de admissão; b) Tempo de Compressão; c) Tempo de Combustão; d) Tempo de Exaustão. Também são mostrados os principais componentes do motor: 1) Came de Válvula de Admissão; 2) Bico injetor; 3) Válvula de admissão; 4) Válvula de exaustão; 5) Câmara de combustão; 6) Pistão; 7) Parede dos Cilindros; 8) Biela; 9) Virabrequim; 10) Came de Válvula de Exaustão.

Para que um motor de combustão interna seja cada vez mais eficiente, ele deve aproveitar a maior parte da energia química contida no combustível e transformá-la em energia cinética. O ciclo termodinâmico mais eficiente e de referência para outros ciclos é conhecido como ciclo de Carnot, no qual as perdas são reversíveis. Em motores reais, as perdas podem ser explicadas pela ocorrência de atrito entre as partes do motor e pela eficiência do aproveitamento da combustão pelo processo, tornando as perdas irreversíveis

Figura 3 – Ciclo de um motor 4 tempos.



Fonte: (REIF, 2014)

(CURZON; AHLBORN, 1975). Os projetos dos motores devem buscar a maior eficiência energética com baixos níveis de emissão de poluentes.

Os motores são nomeados pelo seu ciclo de funcionamento termodinâmico, não pelo combustível que utilizam. Existem vários ciclos termodinâmicos, usualmente os motores de combustão interna utilizam em seus projetos os preceitos do ciclo Otto ou Diesel.


Um dos fatores que influenciam diretamente a eficiência de um motor de combustão interna é sua taxa de compressão. A taxa de compressão é a razão existente entre o volume da câmara de combustão no ponto morto inferior (BDC na figura 3a) e o volume no ponto morto superior (TDC na figura 3a). Os motores Diesel apresentam taxas de compressão elevadas quando comparado a outros motores. A sua construção deve ser capaz de resistir a essas taxas e, por isso, são mecanicamente reforçados, aumentando seu peso e vida útil.

## 2.2 Subsistemas

O bom funcionamento de motores Diesel depende do correto funcionamento de seus subsistemas, que dão suporte para que o ciclo funcione com maior eficiência, reduzindo a quantidade de Diesel consumido e aumentando a vida útil de todo o equipamento. Os principais subsistemas de um motor Diesel são: sistema de injeção, sistema de controle, sistema de admissão de ar, sistema de lubrificação e sistema de arrefecimento (XIN, 2011). Estes subsistemas podem ser montados diretamente ao bloco do motor ou em partes diversas do equipamento em que estão empregados.

A figura 4 apresenta a disposição dos principais componentes do motor Diesel com alguns dos subsistemas auxiliares: 1) Eixo de comando; 2) Válvulas; 3) Pistões; 4) Sistema de injeção; 5) Cilindros; 6) Recirculação de gases de exaustão; 7) Tubulação de Admissão de ar; 8) Turbocompressor; 9) Tubo de exaustão; 10) Sistema de arrefecimento; 11) Biela; 12) Sistema de lubrificação; 13) Bloco; 14) Virabrequim; 15) Amortecedor Dinâmico.

Figura 4 – Disposição dos principais componentes de um motor Diesel.



Fonte: (REIF, 2014)

### 2.2.1 Sistema de Injeção

O sistema de injeção é estreitamente ligado ao sistema de controle do motor Diesel, esses dois têm em conjunto papel essencial no aumento da eficiência térmica final do motor. O seu principal propósito é possibilitar que o combustível seja entregue aos cilindros na quantidade correta e no momento correto. Garantir esses dois pontos não garante uma boa combustão, também esse sistema deve ser capaz de atomizar o combustível e facilitar a mistura entre o ar e combustível (MAGDI; JääSKELÄINEN, 2013).

Os principais componentes que fazem parte desse sistema são bomba injetora e bico injetor. Esses devem ser capazes de reagir mecanicamente com precisão e velocidade solicitadas pelo sistema de controle, só assim eficiências energéticas mais altas são atingidas, melhorando a combustão.

Nas locomotivas, assim como em automóveis, esse sistema vem evoluindo para atender a critérios internacionais de emissão e eficiência. Esse sistema já passou de injeção puramente mecânica para eletrônica. Hoje é utilizado com frequência o Common-rail (ALPTEKIN, 2017; LIU; YAO; YAO, 2015). Em um futuro próximo, novas tecnologias já prometem eficiência de até 60% para os motores com mudanças exclusivas desse sistema.

### 2.2.2 Sistema de Controle

Tipicamente, uma unidade de controle de motor (ECU) incluem um microcontrolador e uma unidade de processamento de tempo (TPU). A TPU é responsável em sincronizar os comandos do microcontrolador com os tempos mecânicos do motor. O microcontrolador dos ECU são mais lentos que microcontroladores usados em *desktops* devido a considerações de compatibilidades eletromagnéticas (GUZZELLA; ONDER, 2009). O ECU é responsável em gerenciar todos os sinais dos sensores tomando ações para que o motor cumpra sua missão, melhorando a eficiência térmica do motor.

### 2.2.3 Sistema de Admissão de Ar

Quanto maior a potência do motor maior a quantidade de ar admitida pelos cilindros, sendo eventualmente necessários o uso de sopradores ou turbocompressores. Locomotivas em geral utilizam motores soprados ou turbinados, desta maneira, conseguem atingir as altas potências de trabalho. As mais modernas contam até mesmo com dois turbocompressores, uma para cada lado do motor.

### 2.2.4 Sistema de Lubrificação

O sistema de lubrificação, além da sua função de manter as partes móveis separadas, tem a função de auxiliar no arrefecimento, de proteger as partes contra corrosão, impactos, reduzir ruídos e de manter a limpeza interna do motor (BASSHUYSSEN; SCHÄFER, 2004). A lubrificação pode ser feita por várias substâncias químicas em diferentes estados. Hoje é comum materiais auto-lubrificantes, em que a estrutura físico-química do material contém lubrificantes. O lubrificante é considerado um elemento de máquina, nos mancais ele transfere forças mecânicas pelo filme de óleo formado entre as partes.

Esse sistema é constituído de vários componentes, valendo ressaltar o seu reservatório, a bomba de óleo e o resfriador de óleo. O circuito que o óleo percorre pelos componentes traz muita informação do que está ocorrendo na máquina. É comum realizar a análise química do óleo lubrificante do motor para a tomada de decisão quanto a manutenção ou condição de vida do motor.

### 2.2.5 Sistema de Arrefecimento

O sistema de arrefecimento tem como função melhorar a condição de troca de calor da combustão com o ambiente, mantendo a temperatura do motor a níveis aceitáveis de projeto. Motores trabalhando em temperaturas mais baixas tendem a consumir menos combustível. Os componentes que usualmente fazem parte do sistema de arrefecimento de um motor Diesel são: bomba d'água, responsável em gerar a pressão necessária para que o fluido de arrefecimento escoe por todo o motor; *intercoolers*, que retiram calor do ar de admissão para melhorar condições da combustão fazendo assim parte de ambos os sistemas de arrefecimento e de admissão; radiadores, principal trocador de calor com o ambiente; caixa de expansão, permite a expansão de possíveis vapores e função de reservatório do fluido de arrefecimento.

Usualmente, o fluido de arrefecimento utilizado por esse sistema é água destilada com aditivos, necessários para aumentar seu ponto de ebulição, reduzir a temperatura de congelamento do fluido de arrefecimento e evitar corrosão interna das tubulações.

## 2.3 Falhas comuns

Em um contexto geral, as causas mais comuns de falhas em motores Diesel são vazamentos, causados por problemas como falhas de montagem e juntas de vedação.

O sistema de injeção, sofre com água vinda do tanque de combustível, pois o Diesel tem características higroscópicas favorecendo a corrosão de bico e bombas injetoras. As locomotivas geram oscilações da potência e grimpamento de bombas. No Brasil, com o aumento da porcentagem de biocombustível misturado ao Diesel, esse problema é aumentado. Nas locomotivas, algumas com tanques de 15.000L, esse é um problema recorrente.

Falhas no sistema de admissão de ar são causadas por problemas relativos a filtros entupidos ou mal limpos. Em motores Diesel de maior porte, caso da locomotiva, que necessitam de sopradores ou turbocompressores, os vazamentos ocorrem ocasionalmente gerando redução de potência ou perda de eficiência do motor, quando há problemas com o turbocompressor é verificado oscilação de carga. Vazamentos são pouco frequentes nas locomotivas, mas existe volume de falhas com turbocompressores e sopradores de ar a serem considerados.

A degradação do óleo lubrificante é o problema mais comum no sistema de lubrificação. Vazamentos ocorrem, mas são detectados rapidamente, pois falhas na lubrificação tendem a causar falhas catastróficas ao motor, além de causar possíveis impactos ambientais.

No sistema de controle, hoje altamente computadorizado, busca-se manter tempera-



turas abaixo de 70 graus Celsius, reduzindo o envelhecimento ou queima dos componentes eletrônicos. Uma falha comum nesses sistemas são falhas de sensores, pois estes estão sempre submetidos ao trabalho do equipamento. Nas locomotivas pode-se perceber falhas frequentes dos módulos eletrônicos.

As falhas típicas dos sistemas de arrefecimento em motores Diesel ao decorrer do tempo e de sua utilização são descritas por (RAWSON, 2016; REED, 2015; SERVICE, 2013) e destacam-se as mais comuns. O entupimento das tubulações causadas por saturação dos filtros e corrosão da própria tubulação, reduzem a pressão em certos pontos do motor. Vazamentos causados por problemas de vedação das partes fixas e móveis do motor, caso de selos de bombas, são falhas recorrentes. Falhas do ventilador do radiador reduz a capacidade de troca de calor, fazendo com que a temperatura não fique em níveis aceitáveis de operação. Também podem ocorrer falhas aparentes do sistema de arrefecimento, como falhas de sensores pertencentes ao sistema de arrefecimento.

A indústria utiliza motores Diesel como fonte de diversos tipos de energia e para evitar tais falhas vem aprimorando formas de detecção e diagnóstico das mesmas. Motores mais antigos continham sensores basicamente para aumentar sua eficiência energética e a detecção de falhas era tratada com menos prioridade. Esses equipamentos mais antigos indicavam falhas somente quando atingiam certos níveis de alarme, em que já não era mais possível evitar a parada do motor.

Hoje os fabricantes de motores Diesel vêm aprimorando os sistemas de diagnóstico, adicionando mais sensores, e utilizando outros métodos para antecipar possíveis falhas e ou paradas inesperadas da operação. Usualmente, estes sistemas têm alto custo e não estão disponíveis para as equipes de operação e manutenção. Com isso, grande parte da indústria utiliza ainda mão de obra, realizando inspeções frequentes nos motores na tentativa de antecipar e diagnosticar possíveis falhas.

## 2.4 Locomotiva e o Motor Diesel Ferroviário

Em uma locomotiva, a principal variável a ser controlada é a potência fornecida aos motores de tração, a velocidade do trem é consequência física das cargas impostas a locomotiva.

As locomotivas Diesel-Elétricas apresentam os chamados pontos de potência, doravante denominados *notch*. Usualmente, as locomotivas apresentam 9 *notchs*, cada um define uma potência diferente para os motores de tração. O primeiro é marcha lenta, onde o gasto energético existe somente para manter os equipamentos auxiliares da locomotiva e funções básicas ao maquinista, não disponibilizando energia para tração. Os outros 8 *notchs* são utilizados para tração da locomotiva.

Como a inércia dos motores de Diesel ferroviários é maior, devido ao seu tamanho, não é vantajoso que a velocidade do motor (BASSHUYSEN; SCHÄFER, 2004) seja alterada constantemente, ou até mesmo para cada um dos *notchs*. A aceleração do motor exige injeção de um volume maior de combustível que será queimado de maneira menos eficiente do que a queima do volume injetado quando o a velocidade do motor esta em regime permanente, reduzindo sua eficiência energética nessas situações. Motores de mesma potência, que operam em altas velocidades, desperdiçam parte da energia com o sistema de lubrificação e motores que operam em baixa rotação exigem maior capacidade estrutural das partes móveis do motor.

Nas locomotivas Diesel-Elétricas, como cada *notch* altera a potência que é demandada ao motor, caso a velocidade do motor fosse mantida baixa, o torque no eixo virabrequim ultrapassaria sua capacidade estrutural. Por esse fato e da eficiência energética, a estratégia de controle utilizada comumente nas locomotivas é fazer somente poucas mudanças de velocidade, acelerando o motor somente quando a exigência de torque sobre o eixo chegue próximo ao seu limite de segurança estrutural. Com isso, usualmente, o número de velocidades de regime do motor é menor que o número de *notchs*.

### 2.4.1 Locomotiva DASH9-40BBW


A locomotiva selecionada neste trabalho é uma locomotiva modelo DASH9-40BBW fabricada pela General Electric. A potência fornecida aos seus 8 motores de tração de corrente contínua é de 4000HP. Apresenta capacidade de realizar teste de auto-carga, que permite que a máquina seja testada em condições normais de operação. Nesse teste, a potência produzida pelo alternador é direcionada à grades de freio dinâmico, resistências montadas na parte superior da locomotiva, capaz de receber toda energia que é desviada dos motores de tração.

O modelo de motor Diesel utilizado por essa locomotiva é o 7FDL16, que tem como características: 4100HP, 16 cilindros montados em V com 10,5 litros cada, velocidade máxima do motor de 1150 revoluções por minuto, 2 *intercoolers*, um turbocompressor e um peso total de 19 toneladas.

Nessa locomotiva o motor apresenta um total de 8 sensores: 1 sensor de posição de ângulo do motor, 2 sensores para cálculo da velocidade do motor, 1 sensor para temperatura de ar e 1 para a pressão, 1 sensor para a pressão de água de arrefecimento e outro para a temperatura e 1 sensor para a pressão de óleo.

O motor apresenta 5 velocidades diferentes quando está em operação, com a locomotiva operando em 9 diferentes potências. O sistema de controle do motor e o sistema de controle elétrico da máquina trabalham em conjunto buscando manter o equilíbrio entre os dois sistemas, melhorando a eficiência global da máquina e protegendo contra

Figura 5 – Motor Diesel utilizado neste trabalho.

Fonte: [www.get.com](http://www.get.com)

falhas catastróficas. A ECU busca manter a velocidade do motor Diesel especificada para o conjunto de *notchs* estabelecido, em circunstâncias de possíveis falhas, em que a velocidade do motor não seja mantida, a potência demandada pelo alternador ao motor deve ser reduzida para que a sua velocidade seja restabelecida. A tabela 1 apresenta as velocidades do motor Diesel e as potências disponibilizadas aos motores de tração pelo sistema elétrico.

Tabela 1 – Tabela de velocidade do motor e potência para tração da locomotiva.

<i>Notch</i>	Velocidade do Motor (RPM)	Potência p/ Tração (HP)
<i>Idle</i>	335	0
<b>1</b>	335	200
<b>2</b>	440	450
<b>3</b>	580	1000
<b>4</b>	888	1350
<b>5</b>	888	2000
<b>6</b>	995	2800
<b>7</b>	995	3350
<b>8</b>	995	4000

Fonte: Própria

#### 2.4.2 Sistema de arrefecimento da locomotiva DASH9-40BBW

O sistema de arrefecimento da locomotiva estudada apresenta vários itens em comum aos sistemas automotivos em geral, como radiadores, reservatório d'água (caixa de expansão), bomba d'água, galerias e tubulações fazem parte do sistema. As diferenças

começam a surgir em decorrência aos tamanhos envolvidos: os motores da locomotiva apresentam uma inércia térmica elevada, para que possam operar em regime pleno de funcionamento é preciso que atinjam determinadas temperaturas, só assim o motor estará dentro de parâmetros de projeto, prolongando sua vida útil e melhorando seu rendimento.

A figura 6 apresenta um esquemático do sistema de arrefecimento da locomotiva DASH9-BB40W, dando destaque aos principais itens de perda e ganho de calor para o fluido de arrefecimento.

Quando a locomotiva está fria, a válvula WFMV direciona o fluido de arrefecimento diretamente para a caixa de expansão, não passando pelos radiadores, acelerando o processo de aquecimento do motor. Quando a temperatura de regime é atingida, a válvula libera a vazão para os radiadores e é permitido pelo sistema elétrico que a locomotiva eleve sua potência até a máxima permitida.

As bombas de água e óleo do motor Diesel estão ligadas através de engrenagens, conectando o eixo virabrequim do motor com os eixos de acionamento das bombas, sendo assim, suas velocidades angulares são múltiplos da velocidade do motor e razão de engrenamento. Consequentemente, as pressões que as bombas fornecem aos seus sistemas são proporcionais a essa velocidade.

O sensor de pressão e temperatura da água de arrefecimento são instalados antes da entrada do motor. Os sinais desses não são utilizados para cálculos da injeção de combustível pelo sistema de controle do motor, são utilizados somente como dispositivos de proteção.

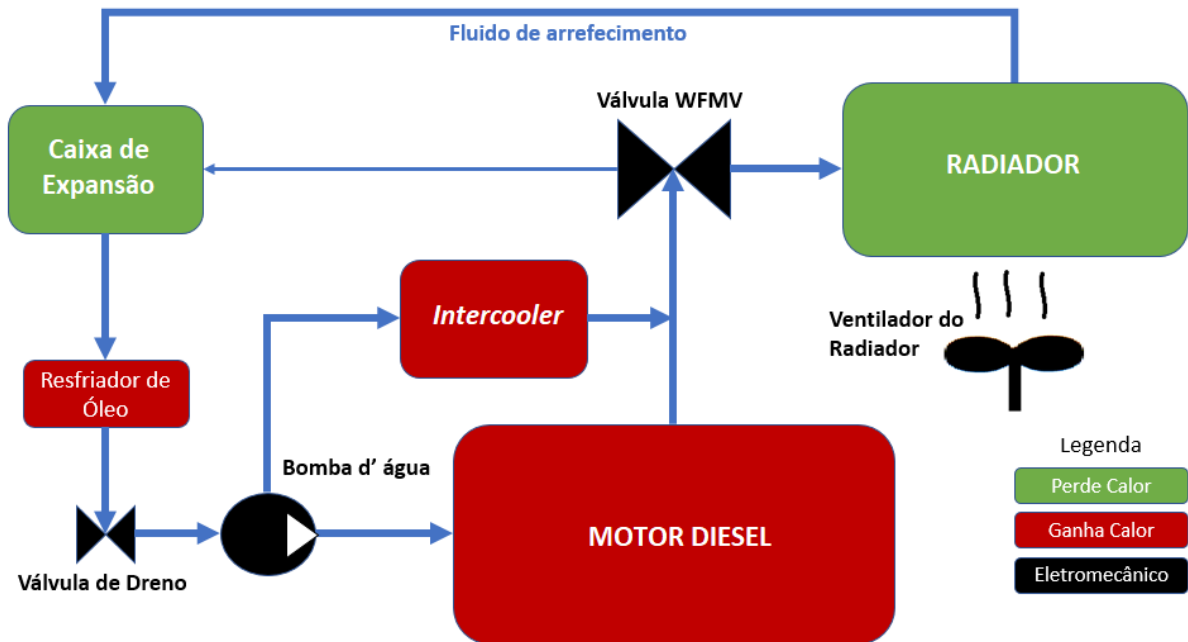
## 2.5 Revisão da literatura de métodos de detecção e diagnóstico aplicados a motores Diesel

### 2.5.1 Detecção e diagnóstico de falhas baseados no conhecimento

A forma mais simples de detecção de falhas é através da checagem de limites operacionais ou de limiares estatísticos de variáveis do processo, tais como pressões, temperaturas e velocidades. Essa abordagem faz o uso da experiência de técnicos verificando as condições dos processos, checando os limites com base em experiência e criando métodos heurísticos baseados nesses conhecimentos.

Várias abordagens de diagnóstico de falhas baseadas no conhecimento têm sido propostas. Estes incluem a abordagem baseada em regras, onde uma regra de diagnóstico pode ser formulada a partir da estrutura do processo e das funções dele, e as abordagens baseadas em simulações. Na abordagem baseada em regras, as falhas geralmente são diagnosticadas casualmente traçando os caminhos de propagação da falha analisada. A lógica

Figura 6 – Sistema de Arrefecimento da Locomotiva testada.



Fonte: Própria

*fuzzy* pode ser usada na abordagem baseada em regras para lidar com informações incertas. Na abordagem qualitativa baseada em simulação, modelos qualitativos de processos são usados para prever o comportamento do processo sob condições normais de operação e em várias situações defeituosas. A detecção e diagnóstico de falhas são então realizados comparando o comportamento predito com as observações reais (PATAN, 2008).

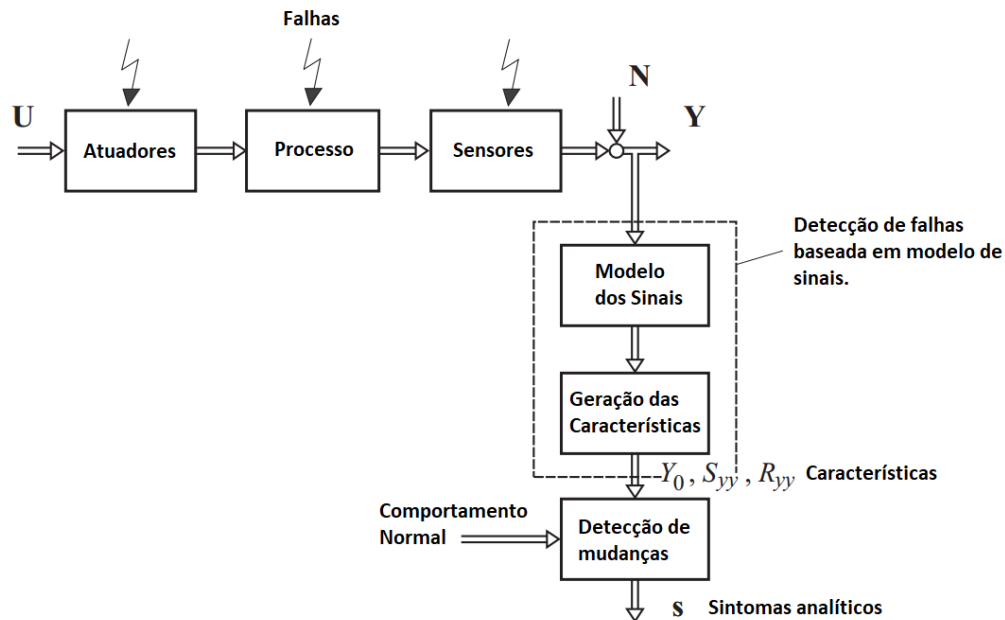
### 2.5.2 Detecção de falhas por análise de sinais

Os métodos de detecção de falhas por análise de sinais, figura 7, em casos mais simples, consistem em verificar se os sinais estão dentro dos limites aceitáveis. Nos casos mais complexos, essas análises verificam a tendência desses sinais, aplicando derivadas temporais e fazendo a checagem de limites. A análise de sinais é a técnica utilizada nas locomotivas DASH9 por uma outra variante do método, o cheque de plausibilidade, onde um conjunto de sinais deixa de apresentar compatibilidade lógica entre eles para que uma falha seja caracterizada (VERSMOLD; SAEGER et al., 2006; ISERMANN, 2016). Dessa maneira, quando a falha é identificada, a locomotiva já não tem mais condições de operar. Como exemplo, se a velocidade do motor for maior que 995 RPM então a pressão de óleo deve ser maior que 30 Psi.

Motores em geral apresentam oscilações harmônicas ou de natureza estocástica, se os sinais que medem essas oscilações mudarem, os métodos de detecção de falhas por sinais podem ser aplicados. A análise de sinais em motores como nos trabalhos de Yang et

al. (2001), Johnsson (2001), Charchalis e Dereszewski (2013) identificam falhas no motor Diesel através da análise do sinal de velocidade do motor, outros trabalhos utilizam os sinais de vibração para identificar problemas (FTOUTOU; CHOUCANE, 2017).

Figura 7 – Detecção e diagnóstico de falhas baseado em sinais.



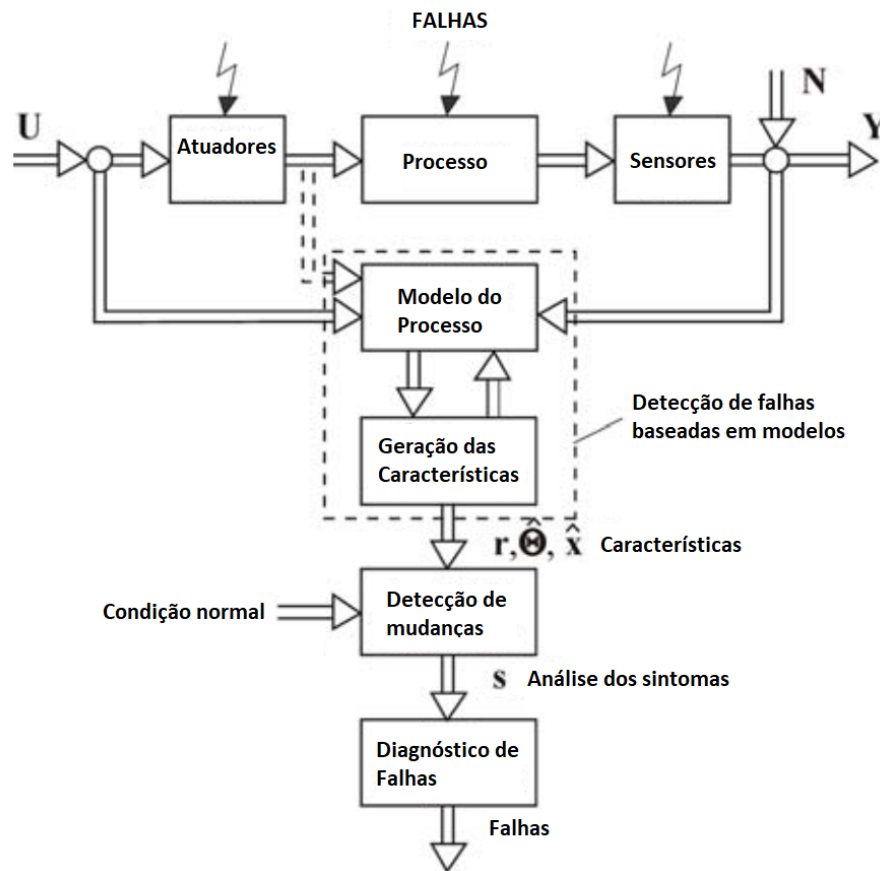
Fonte: Adaptado de Isermann (2016)

### 2.5.3 Detecção e diagnóstico de falhas baseados em modelos do processo

A tarefa de detecção de falhas baseada em modelos do processo consiste em gerar características para a detecção de falhas a partir de estimativas de parâmetros ( $\hat{\theta}$ ), de estados ( $\hat{x}$ ) e resíduos ( $r$ ), a figura 8 apresenta a estrutura de detecção e diagnóstico de falhas baseada em modelos do processo. Comparando essas características com as características normais do processo é possível identificar falhas (ISERMANN, 2005). A estimação de parâmetros (figura 9a), em que os parâmetros da planta são comparados com os parâmetros da planta identificada; equações de paridade (figura 9b), criando um modelo que estima os sinais de saída da planta comparando-os com as saídas reais; estimação de estados e observadores (figura 9c), caso os parâmetros de projeto sejam conhecidos utiliza-se os estados da planta para detecção de falhas, são formas de detecção e diagnóstico de falhas baseadas em modelos de processo (CHEN; PATTON, 2012; ISERMANN, 2005; DING, 2008).

Em muitos casos práticos, os parâmetros são pouco conhecidos ou desconhecidos completamente. Se a estrutura do modelo é conhecida, utiliza-se métodos que os estimam medindo as entradas e as saídas. Assumindo que os parâmetros  $\theta$  tenham significado físico e foram obtidos através de dados de entrada e saída em operação normal do processo, a tarefa

Figura 8 – Esquema de processo de detecção e diagnóstico de falhas baseado em modelos do processo.



Fonte: Adaptado de [Isermann \(2005\)](#)

de detecção de falha consiste em estimar parâmetros  $\hat{\theta}$ . Caso a diferença entre o parâmetro de operação normal e o parâmetro estimado ultrapassar limiares predefinidos a falha pode ser considerada. Entretanto, o problema implica na estimação do parâmetro de forma *online*, que pode ser resolvido por algoritmos recursivos. A principal desvantagem dessa abordagem é que os parâmetros dos modelos devem ter significado físico, correspondente aos parâmetros do sistema. Nessas situações a detecção e diagnóstico da falha é direta, caso não, é regularmente difícil separar a falha de mudanças do vetor  $\theta$  ocasionada por variações temporais do sistema. Muitas vezes, a dificuldade de detecção é ainda maior, pois os parâmetros obtidos não correspondem exclusivamente àquele sistema ([PATAN, 2008](#)).

Se os parâmetros são conhecidos, observadores de estados e observadores da saída do processo podem ser utilizados. [Ceccarelli et al. \(2009\)](#) aplicam esse método para identificar falhas no sistema de vazamento de ar de motores Diesel, fazendo toda a modelagem do sistema e do vazamento inserido nele. Se a reconstrução das variáveis de estado não é relevante ao objetivo da detecção, pode-se fazer o uso de observadores da saída. Dessa



forma, resíduos podem ser modelados independentes dos estados.

As equações de paridade realizam a detecção de falhas fazendo o uso de um modelo fenomenológico ou não da planta, e as saídas desses são comparadas com as saídas reais da planta, gerando os resíduos que posteriormente são analisados. Gertler (1998) menciona que é possível melhorar o sistema de *FDI* quando as equações de paridade são empregadas para caso de várias entradas e várias saídas, gerando resíduos estruturados em que falhas não afetem todos os resíduos. Equações de paridade e estimação de estados, empregados em situação de regime permanente, apresentam resultados similares sem a necessidade de considerações especiais (ISERMANN, 2016). A equação 2.1 apresenta a forma que o resíduo é calculado por paridade entre o processo real  $G_p$  e o processo modelado  $G_M$ ,

$$r(s) = y(s) - y_M = [G_P(s) - G_M(s)]u(s) \quad (2.1)$$

onde  $r$  são os resíduos,  $y(s)$  é a saída da planta,  $y_M$  é a saída do modelo e  $u(s)$  são as entradas.

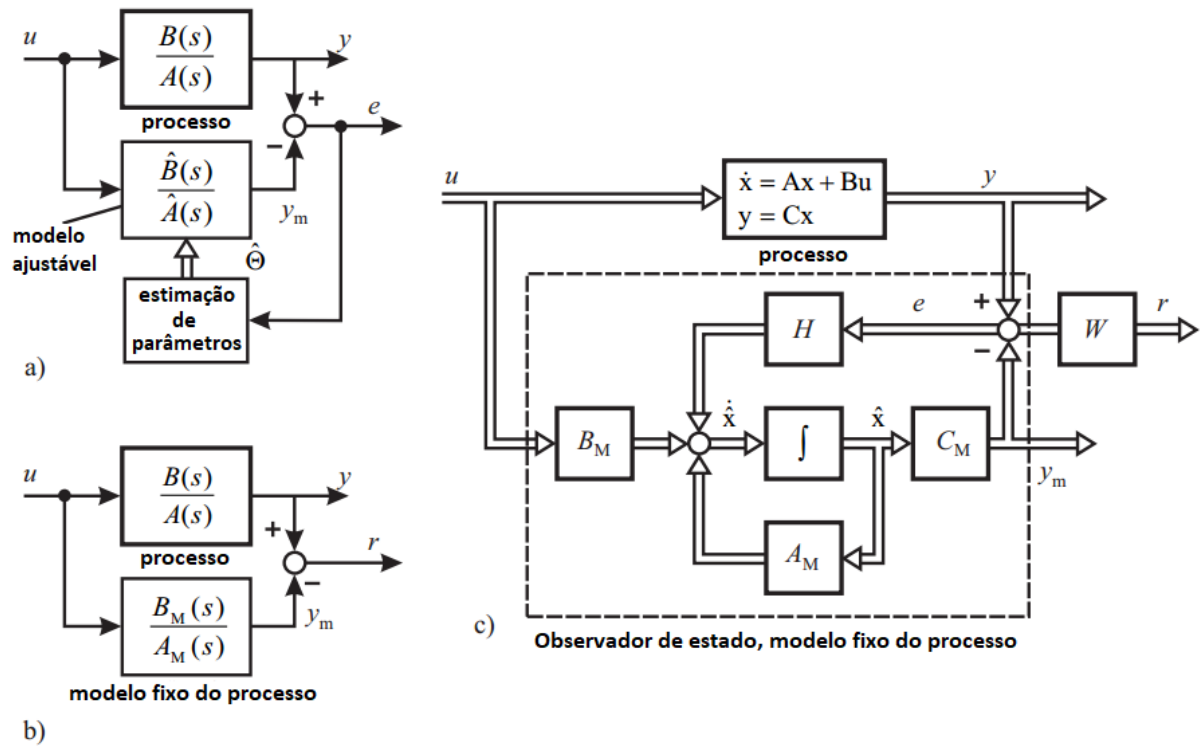
Schwarte e Isermann (2002) detectam falhas do sistema de alimentação de ar do motor Diesel usando resíduos de modelos da eficiência volumétrica, amplitude da oscilação da vazão mássica do motor e oscilação da pressão de ar. Obtiveram bons resultados no momento de diagnosticar as 6 possíveis falhas propostas no seu estudo. Khelil et al. (2012) fazem a detecção de problemas com o sistema de lubrificação de um motor Diesel marítimo fazendo a identificação paramétrica do sistema, gerando resíduos entre os sinais reais dos sensores e a saída dos modelos. Isermann (2016) apresenta de forma gráfica métodos de detecção de falhas baseadas em modelos do processo mais comuns, esses esquemas são apresentados na figura 9.

Definidas as características de saída a serem analisadas, faz-se a detecção por meio do uso de ferramentas estatísticas univariadas, multivariadas ou por classificadores (CHIANG; RUSSELL; BRAATZ, 2000). A estatística univariada pode ser vista quando busca-se analisar uma variável e se o valor dessa extrapolar limites estatísticos (limiares estatísticos) a falha é caracterizada. Essa abordagem geralmente é feita utilizando as cartas de controle de Shewhart. Os limites de controle da carta devem ser bem definidos buscando a relação ótima entre a detecção de falhas falsas e verdadeiras. Schwarte e Isermann (2002) fazem o uso dessas cartas para caracterizar a existência de falhas em motores.

Na prática, devido às incertezas existentes na modelagem e ruídos nas medidas, é preciso ajustar os limiares para valores maiores buscando evitar falsos alarmes. Isso causa a redução na sensibilidade de detecção e por essa razão é recomendado que os limiares sejam adaptados. Uma ideia de adaptação é calcular características estatísticas de amostras passadas de dados e, através delas, fazer as correções. Nisto, o maior problema torna-se em selecionar o correto tamanho da janela de dados passados (PATAN, 2008).



Figura 9 – Principais métodos de detecção de falhas baseadas em modelos do processo. **a** estimação de parâmetros, **b** estimação de estados, **c** equações de paridade.



Fonte: Adaptado de [Isermann \(2005\)](#)

Outras cartas como de soma cumulativa e de filtros exponencial de média móvel são empregados. A carta de soma cumulativa facilita a análise de tendências existentes nas variáveis, além de geração de possíveis características para o diagnóstico. Através destas cartas, [Boulkroune, Aitouche e Cocquempot \(2013\)](#) detectam e diagnosticam problemas com atuadores de válvulas de recirculação de gases de exaustão de motores Diesel modernos.

A etapa de diagnóstico é a etapa em que as falhas já detectadas são quantificadas quanto a sua amplitude, tipo, momento e local em que ocorrem por meio dos sintomas apresentados. [Isermann \(2016\)](#) afirma que o procedimento de diagnóstico das falhas parte de observações analíticas, sintomas heurísticos e conhecimento heurístico do processo. Se não existir nenhum outro conhecimento sobre as relações existentes entre variáveis, emprega-se métodos de classificação ou reconhecimento de padrões. Isso é feito por meio da análise das características dos sinais de saída ou das características geradas pelos modelos de detecção, comparando-as com padrões de funcionamento normais do processo já conhecido.

[Chen e Patton \(2012\)](#) estruturam seus modelos de detecção para que todas as características de saída sejam vistas como resíduos e afirmam que o sucesso da detecção é

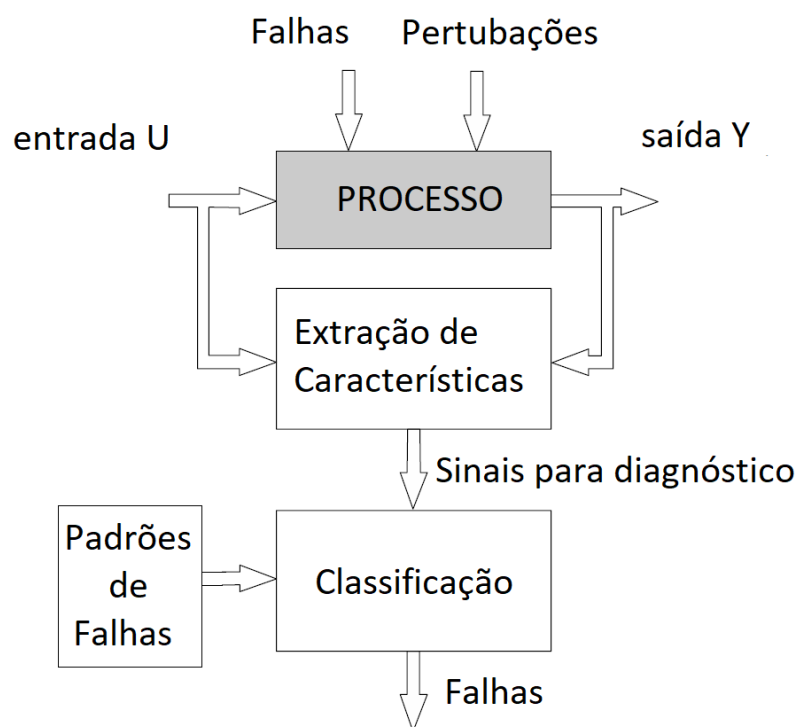
seguido pelo procedimento de isolamento que irá distinguir uma falha em particular de outra. Eles declaram que se um vetor de resíduos pode isolar todas as falhas, pode-se dizer que esse vetor apresenta todas as propriedades requeridas para o isolamento.

Nyberg (1999) em seu trabalho diferencia 3 tipos diferentes de vazamentos de ar do sistema de um motor automobilístico utilizando ferramentas estatísticas de classificação. Modelando o motor e as falhas é possível, através da estruturação de testes de hipóteses estatística, realizar o diagnóstico, assim como fazem Kimmich, Schwarte e Isermann (2005), com o extensivo uso de limiares estatísticos para diferentes sinais, realizando o diagnóstico no mesmo sistema.

#### 2.5.4 Detecção e diagnósticos de falhas por classificadores

Outra maneira de realizar a detecção e diagnóstico de falhas é pelo uso dos dados de operação do processo, em que esses são adquiridos nas condições de operação normal e com falhas, todos devidamente rotulados. Por meio deles é extraído o conhecimento para realizar o diagnóstico. Isermann (2016) e Patan (2008) afirmam que os processos de diagnóstico podem ser realizados por métodos estatísticos ou por classificadores. Patan (2008) apresenta esquema de detecção e diagnóstico de falhas por meio de classificadores, extraíndo características dos sinais de entrada e saída do processo analisado. Esse esquema pode ser observado na figura 10.

Figura 10 – Esquema de diagnóstico de falhas através do uso de classificadores



Fonte: Adaptado de Patan (2008)

A estatística multivariada como a estatística  $T^2$  de Hotelling é amplamente empregada na detecção e diagnóstico de falhas em processos industriais, juntamente com a análise de componentes principais (PCA) (CHIANG; RUSSELL; BRAATZ, 2000). Wang et al. (2008) fazem uso da estatística multivariada e de PCA não linear para detectar e diagnosticar falhas no sistema de admissão de motores Diesel. Em (ANTORY et al., 2005) é feito o uso de PCA não-linear para diagnosticar falhas sem a necessidade de criação de modelos.

O diagnóstico de falhas utiliza a ideia da classificação, que é de estabelecer a qual classe ou categoria pertence um determinado dado. Na mineração de dados, a classificação tem um papel de protagonista com a tarefa de generalizar uma estrutura já conhecida e aplicá-la a um novo dado (HÄMÄLÄINEN; VINNI, 2011).

Todo projeto de classificação de dados deve seguir certas premissas e regras, comuns entre todos os projetos, para que esse possa obter sucesso. Os dados devem estar disponíveis, ser relevantes, adequados e limpos, o problema precisa estar bem definido, preferencialmente não podem ser resolvidos por meios ordinários e os resultados devem ter significado (PATEL; PRAJAPATI; LAKHTARIA, 2012).

Existem várias técnicas voltadas para a tarefa de classificação. Os classificadores mais comuns são

(NEELAMEGAM; RAMARAJ, 2013):

- Árvore de decisão
- Vizinhos mais próximos (kNN);
- Máquina de vetores de suporte (SVM);
- Classificação Naive Bayes;
- Redes neurais artificiais (ANN);

Os métodos de diagnóstico baseados em classificadores surgem da ideia de que a trajetória de uma nova amostra é similar àquelas dos dados de treinamento, dados de operação normal terão uma trajetória, enquanto dados de falhas, outra. Uso de classificadores dispensa o uso de modelos do processo, evitando problemas causados, por exemplo, por não linearidades (HE; WANG, 2011).

He e Wang (2011) utilizam o classificador do tipo kNN para realizar a detecção e diagnóstico de falhas de lotes de semicondutores e compara à métodos estatísticos. O classificador do tipo kNN pode ser encontrado em vários trabalhos de detecção e diagnóstico de falhas, principalmente em processos produtivos de semicondutores (WANG; LIU; LI, 2015). Uma aplicação interessante é feita por Li e Wu (2017), em que testam vários

classificadores, entre eles o kNN, destacando-se pelas formas de extração de características dos sinais de um motor a gás.

A rede neural artificial (ANN) em vários trabalhos vem se apresentando como um ferramenta poderosa de classificação e de reconhecimento de padrões, e o resultado disso é que hoje é um dos métodos de classificação mais utilizados no diagnóstico de falhas (LIU et al., 2018). Chen et al. (2012) empregam ANN juntamente com algoritmos genéticos para seleção das melhores características de entrada para a rede, diagnosticando problemas internos do motor com resultados de acertos de até 100% para casos de falha de ignição. Ahmed et al. (2015), Shatnawi e Al-Khassaweneh (2014) também empregam ANN para diagnosticar problemas diversos de motores de combustão interna e Flett e Bone (2016) diagnosticam problemas de eixo de comandos de válvulas de motores Diesel.

## 3 Metodologias propostas

Nesse capítulo são apresentadas duas abordagens diferentes para a detecção e diagnóstico de falhas do sistema de arrefecimento de motores Diesel: uma baseada em modelos do processo e outra usando classificadores. Na abordagem baseada em modelos do processo são apresentados os métodos de geração dos modelos, as métricas de seleção dos modelos empregados e como é feita a detecção de falhas no sistema de arrefecimento. Na abordagem por classificadores, são selecionados dois classificadores, escolhidas as características de entrada, como é feito o treinamento e as métricas de avaliação de seu desempenho.

### 3.1 Coleta dos dados

No mercado estão disponíveis vários tipos de plataformas de desenvolvimento que facilitam a coleta de dados. Neste trabalho é utilizado o *BeagleBoneBlack Rev C*, programado em *Python*, possibilitando o embarque do sistema de detecção e diagnóstico na locomotiva.

Todos os algoritmos de análises são desenvolvidos com as rotinas existentes no software *MATLAB*, enquanto que os algoritmos do dispositivo de aquisição dos dados utiliza bibliotecas *Python*.

A ECU da locomotiva disponibiliza quantidade de dados previamente calculados e filtrados analogicamente e digitalmente, somente 8 dados são disponibilizados continuamente. A ECU envia esses dados de forma assíncrona, entre  $4Hz$  e  $5Hz$ . Opta-se em interpolar linearmente os dados a uma frequência de  $20Hz$ , para identificação temporal da amostra e redução de vazamento espectral no caso de análise de características no domínio da frequência (ZHANG et al., 2014). Toma-se as devidas precauções técnicas após a interpolação para que as análises não sejam feitas com frequências acima de  $4Hz$ . Além disso, a interpolação de dados facilita o entendimento temporal dos dados visto que cada amostra, mesmo que interpolada, pode ser identificada facilmente.

A locomotiva DASH9-40BBW selecionada para a coleta dos dados deve estar disponível e em ótimas condições de funcionamento e com todas as manutenções em dia, com o nível de água de arrefecimento dentro do padrão e mesma situação para todos os parâmetros de checagem física do motor.

A locomotiva será colocada em estado de auto-carga. É preciso aguardar que a locomotiva esteja dentro dos parâmetros estabelecidos de regime para dar início as coletas de dados, evitando que a locomotiva fique fora das condições normais de operação. Dado

início a coleta de dados, o dispositivo recebe os 8 sinais selecionados, temperatura e pressão de ar é água, pressão de óleo, velocidade do motor Diesel, volume de combustível injetado e posição do regulador de carga. O próprio dispositivo de coleta adiciona um rótulo de tempo ao vetor de dados no momento em que o computador da locomotiva os envia.

Para testar a metodologia são feitas mudanças frequentes dos *notchs* da locomotiva em auto-carga. Essas mudanças são feitas de forma aleatória e várias vezes. Entre as alterações dos *notchs* é aguardado até que a locomotiva atinja a potência de regime para aquele *notch*, antes que seja feita outra alteração. Dessa maneira são coletados os dados de operação normal e com o vazamento de água de arrefecimento pela válvula de alívio manual do sistema. O vazamento será inserido apenas uma única vez, pois testes com esse motor consomem por volta de 500 litros de Diesel por hora.

## 3.2 Detecção de falhas baseada em modelos do processo

Para detecção de falhas no sistema de arrefecimento são utilizados os sinais de velocidade do motor, pressão e temperatura da água recebidos pelo ECU. Como a velocidade da bomba d'água está diretamente ligada a velocidade do motor, a pressão também está relacionada a essas velocidades. Por esse motivo, nessa abordagem do trabalho define-se como ponto de operação as 5 velocidades do motor Diesel, e não os 9 *notchs* de potência da locomotiva.

As transições de velocidade do motor usado são rápidas quando comparadas ao tempo em que esse permanece nas velocidades pré-estabelecidas do motor pelo sistema de controle, que são: 335, 440, 580, 888 e 995 RPM. Nesses pontos de operação os sinais são considerados em regime permanente, e é nessas condições que se deseja detectar as falhas do sistema de arrefecimento.

Os diferentes pontos de operação apresentam diferentes momentos estatísticos. Portanto, o ponto de operação permite escolher os modelos com seus limiares correspondentes, ou então, realizar normalização que permita usar o mesmo limiar para todos os pontos de operação. Para detecção de falhas utilizando cartas de Shewhart e de soma cumulativa sem a necessidade da criação de algoritmos complexos de adaptação de limiares, faz viável a detecção do ponto de operação.

### 3.2.1 Detecção do ponto de operação

Dentre os muitos classificadores existentes, utilizou-se o tipo *kNN*, dada teoria madura, fácil interpretação e implementação. Definiu-se para seu treinamento 6 classes, 5 são as velocidades pré-estabelecidas e uma para a transição entre as velocidades. Os dados usados pelo classificador são a velocidade do motor e sua variação.

Para rotular os dados, admite-se como pertencente a cada classe velocidades do motor com valores de  $\pm 10$  RPM da velocidade nominal da classe. A variação da velocidade é calculada pela diferença da velocidade no instante menos a velocidade medida de 20 amostras antes (lembrando que a frequência de amostragem é 20Hz).

A rotina *knnsearch* do *Matlab* com método de procura *kd-tree* será utilizada pelo classificador, com 10 vizinhos mais próximos medidos por distância euclidiana.

O desempenho do classificador deve atender uma especificidade acima de 95% (fração dos dados não pertencentes à uma classe corretamente classificados, equação 3.1), e uma sensibilidade acima de 95% (fração dos dados pertencentes à uma classe corretamente classificados, equação 3.2). O classificador implementado deve detectar os pontos de operação da locomotiva e as transições durante as quais não são feitas as detecções.

$$Especificidade = \frac{QV_N}{QV_N + QF_P} \quad (3.1)$$

$$Sensibilidade = \frac{QV_P}{QV_P + QF_N} \quad (3.2)$$

Onde:  $QV_N$  é número de verdadeiros negativos,  $QV_P$  número de verdadeiro positivos,  $QF_N$  número de falsos negativos e  $QF_P$  número de falsos positivos

### 3.2.2 Modelos e geração de resíduos

As técnicas de modelagem acima serão utilizadas para obtenção de modelos únicos que representam todos os pontos de operação e modelos múltiplos, um por ponto de operação. No primeiro caso, as entradas do modelo são a velocidade e a temperatura e a saída é a pressão. O segundo caso, a saída é a mesma e a entrada é apenas a temperatura, pois a velocidade do ponto de operação é conhecida.

As técnicas de modelagem para determinar os modelos que representem um ou todos os pontos de operação testadas neste trabalho com seus respectivos parâmetros, são:

- Rede neural de regressão generalizada (*GRNN*), com fator de suavização de 0.2.
- Regressão por máquinas de vetores de suporte (*SVR*) usando função gaussiana.
- Regressão Polinomial (*POLY*) com polinômios de até quinto grau.
- Árvore de regressão (*TREE*) com modelo de regressão particionado.

Para isso, são utilizadas as rotinas do *Matlab*: *newgrnn*, *fitrsvm*, *fit* e *fitrtree*, respectivamente. Os demais parâmetros foram os *default* dessas rotinas.

Serão selecionados os modelos que obtiverem o maior coeficiente de Spearman entre a saída real e a saída estimada e com a condição de que o erro (RMSE) seja menor que o erro médio dentre os modelos gerados, Kuhn e Johnson (2013) sugerem essas métricas para medir o desempenho de modelos de regressão. Parâmetros como o critério de informação de Akaike (AIC) e de informação Bayesiana (BIC) não serão utilizados, pois o número de variáveis de entrada para cada modelo já foi pré-estabelecido.

A validação cruzada é feita aplicando o *repeated K-fold* que utiliza sucessivos conjuntos (*folds*) gerando uma maior massa para análise estatística, tornando a seleção do modelo mais confiável (KUHN; JOHNSON, 2013; REFAEILZADEH; TANG; LIU, 2009). Os dados para gerar cada *fold* são selecionados aleatoriamente a cada iteração do *repeated K-fold*. São testadas todas as técnicas de determinação de modelos apresentadas.

Faz-se 50 repetições com 10 *folds*, resultando em 500 modelos a cada teste. Um maior número de repetições permite caracterizar melhor as estatísticas usadas para a escolha dos modelos. O número de repetições é escolhido assegurando um baixo esforço computacional. A rotina *crossval* do *MATLAB* é utilizada nessa etapa da modelagem.

Como o coeficiente de Spearman é calculado pelo posto dos dados estimados em relação ao posto dos dados reais, espera-se que o modelo assim selecionado apresente os menores erros de estimativas para novas entradas, mesmo não tendo necessariamente produzido o menor erro para o conjunto de dados usados.

### 3.2.3 Análise dos resíduos e detecção de falhas

Uma forma usual para detecção de falhas é o emprego de estatística univariada, onde o vetor dos resíduos será avaliado utilizando cartas de controle de Shewhart (BISWAS; MASUD; KABIR, 2015; KISIĆ et al., 2013). Se os resíduos gerados pelos modelos apresentarem diferentes médias e variâncias para cada ponto de operação, a normalização dos resíduos deve ser diferente em cada região, para que se possa utilizar um único limiar.

No caso de utilização de cartas de soma cumulativa, o vazamento é detectado no momento em que o limite inferior é atingido. Esse limite é calculado iterativamente no vetor de treinamento até que não sejam observados falsos positivos. A soma da carta é feita usando uma janela móvel. O tamanho da janela determina a sensibilidade da carta a desvios de médias, sendo de 3000 amostras neste trabalho.

Os modelos geram os resíduos durante a operação do motor. Caso o classificador indique que o motor esteja entre os pontos de operação (transição), deve-se atribuir ao resíduo valor zero.



Tabela 2 – Vantagens e desvantagens dos classificadores utilizados.

Classificador	Vantagens	Limitações
<b>kNN</b>	<ol style="list-style-type: none"> <li>1. Teoria madura e fácil de implementar</li> <li>2. Fácil entendimento.</li> </ol>	<ol style="list-style-type: none"> <li>1. Custo de computação alto</li> <li>2. Exige muita memória</li> <li>3. Valor de k exerce muita influência</li> </ol>
<b>ANN</b>	<ol style="list-style-type: none"> <li>1. Alta acurácia de classificação</li> <li>2. Boa aproximação de funções não lineares complexas</li> </ol>	<ol style="list-style-type: none"> <li>1. Muitos parâmetros e fácil ocorrência de <i>over-fitting</i></li> <li>2. Sem significado físico</li> <li>3. Processo de aprendizado não pode ser visto.</li> </ol>

Fonte: (LIU et al., 2018)

### 3.3 Detecção e diagnóstico de falhas com o uso de classificadores

Uma das alternativas para a detecção e diagnóstico de falhas sem a necessidade de criação de modelos do processo é através do uso de classificadores. Para esta tarefa são extraídas características dos sinais recebidos pelo sistema de controle. Para detectar e diagnosticar falhas no sistema de arrefecimento, os dados utilizados continuaram sendo velocidade do motor e pressão de água de arrefecimento, e desses sinais são extraídas as características estatísticas.

Para essa abordagem, como também serão feitos diagnósticos, é introduzida uma nova falha de queda de pressão. Com isso, os dados são separados em 3 classes: A primeira classe (Classe 1), irá conter dados de operação normal do motor com ausência de falhas, a segunda (Classe 2) queda de pressão, impondo um decréscimo de 5% em uma seção do vetor de dados de pressão, e uma terceira classe (Classe 3), contendo dados do vazamento de água de arrefecimento do motor Diesel.

Os classificadores utilizados são o *kNN* e redes neurais artificiais (ANN) sendo comparados pelas métricas de avaliação de desempenho. A escolha baseou-se nas premissas apresentadas na tabela 2, em que apresenta as vantagens e desvantagens dos classificadores utilizados nessa abordagem. A tabela 2 apresenta vantagens e desvantagens de cada um.

#### 3.3.1 Características de entrada dos classificadores

Os quatro momentos estatísticos (média, desvio padrão, curtose e assimetria) bem como as variações dos seus valores que são calculadas subtraindo o valor de cada momento estatístico pelo valor calculado no momento anterior. Esses momentos estatísticos são utilizados como as características de entrada dos classificadores. Para seus cálculos são usadas janelas móveis de tamanhos: 50, 100 e 200.

As características empregadas como entradas dos classificadores são escolhidas em função das respostas obtidas pelas métricas de avaliação de desempenho dos classificadores. Busca-se o menor número de características mantendo o equilíbrio entre a sensibilidade, acurácia e esforço computacional do classificador. Com os três sinais, com os quatro momentos estatísticos e suas variações é possível ao final obter no mesmo conjunto de dados

24 características. Será avaliada a possibilidade de redução do número de características, analisando-as individualmente.

### 3.3.2 Treinamento e testes dos classificadores

Para o treinamento e teste dos classificadores, serão selecionados aleatoriamente 50% de todos os dados das características calculadas disponíveis. Os 50% restantes dos dados serão usados para teste. Dessa forma, espera-se evitar o problema do *over-fitting*, problema comum de classificadores (AZEVEDO; JR, 2002). Nos dados selecionados para treinamento é empregada a técnica de validação cruzada *repeated k-fold*, com 4 *folds* e 80 repetições. A técnica de *repeated k-fold* fornecerá para cada conjunto de janela e parâmetros do classificador testado um total de 320 possíveis classificadores.

### 3.3.3 Classificador kNN

Para o classificador do tipo kNN, a distância de Mahalanobis é utilizada, pois considera a correlação entre os dados. O método de procura dos vizinhos selecionada é o *kd-tree*, padrão da rotina do software *MATLAB*. São testados também, quatro quantidades diferentes de vizinhos, que são: 1, 3, 5 e 7. As classes atribuídas aos dados de treinamento, para o classificador kNN terá valor de 1 para os dados de normais, 2 para a pressão decrescida e 3 para o vazamento real.

### 3.3.4 Classificador ANN

O classificador baseado em redes neurais é testado com diferentes números de neurônios na primeira camada oculta: 2, 5, 10 e 20. Os neurônios apresentam função de ativação do tipo sigmoide, e o método de aprendizagem empregado é o *backpropagation* de gradiente conjugado escalonado. Todo o restante do processo de criação e treinamento da rede é gerenciado pelos valores padrão das rotinas de criação de rede neural *patternnet* e de treinamento *train*, ambas do software *MATLAB*. As classes atribuídas aos dados de treinamento para esse classificador baseados em redes neurais são vetores: [100], [010] e [001] para as classes 1, 2 e 3 respectivamente.

A camada de saída apresenta três neurônios, um para cada classe, tratando-se de um classificador de rede neural, será atribuída classe referente do neurônio com maior valor na camada de saída.

### 3.3.5 Métricas de desempenho de classificadores

Geralmente, a métrica MSE é usada como indicador de desempenho de classificadores (DUIN; TAX, 1998; GIL-PITA; YAO, 2008; LIU; SAKO; FUJISAWA, 2002). Neste trabalho, o MSE é calculado pela soma das diferenças ao quadrado do vetor de classes

reais e o vetor de probabilidades de um elemento pertencer a uma classe gerados pelo classificador, dividindo-a por 3 (3 classes), equação 3.3. Ao final é calculada a média entre todos os MSE dos 320 classificadores gerados e selecionado o melhor classificador do grupo de menor média. Para o classificador ANN as probabilidades são os valores de cada neurônio da camada de saída e para o classificador kNN são as probabilidades a posteriori do elemento pertencer a cada classe.

$$MSE_{médio} = \sum_{i=1}^n \frac{(Pr_{1i} - Pe_{1i})^2 + (Pr_{2i} - Pe_{2i})^2 + (Pr_{3i} - Pe_{3i})^2}{3n} \quad (3.3)$$

Onde:  $Pr_i$  é a probabilidade da classe real e  $Pe_i$  é a probabilidade da classe estimada

Selecionado o classificador, é construída uma matriz de confusão com toda classificação do vetor de treinamento e outra do vetor de testes, visando analisar a capacidade de generalização do classificador escolhido. Por fim, será feita uma breve comparação entre os dois classificadores escolhidos para este trabalho.

## 4 Aplicação e resultados

Neste capítulo são aplicadas as duas abordagens propostas, a de detecção de falhas baseada em modelos do processo e a abordagem que detecta e diagnostica falhas por meio de classificadores. Primeiramente é apresentada a forma de coleta dos dados e o pré-tratamento dado a eles. Em seguida, são apresentados os resultados da primeira abordagem, que são as técnicas empregadas para obtenção e seleção dos modelos dos pontos de operação que geram os resíduos, que são analisados por cartas de controle de Shewhart e soma cumulativa. Após, são apresentados os resultados da segunda abordagem, que utiliza os classificadores kNN e ANN, no processo de detecção e diagnóstico das falhas do sistema de arrefecimento. Ao final, faz-se um comparativo entre os dois métodos.

### 4.1 Coleta de Dados


Por meio de uma rotina criada em *MATLAB* é possível coletar dados das locomotivas. A locomotiva disponível para a coleta de dados no dia de testes estava desligada há mais de 24h, com isso foi necessário aquecer a locomotiva até que essa atingisse as temperaturas de regime. Após aproximadamente 12min, a coleta foi iniciada. Todos os dados referentes aos pontos de operação da locomotiva foram coletados e alterados sucessivamente com a locomotiva em condição operacional sem falhas e, em seguida, foi inserido um vazamento pela válvula de dreno do sistema de arrefecimento da locomotiva. O vazamento apresentou vazão de aproximadamente 5 litros de água de arrefecimento por hora.

Como os dados são enviados assincronamente pelo ECU, optou-se interpolar linearmente todos os vetores de dados para uma única frequência de 20Hz. Nessa frequência de interpolação não houve perdas significativas da amplitude do sinal interpolado. A figura 11 apresenta um trecho dos sinais de velocidade do motor com duas frequências diferentes para interpolação dos dados.

A figura 12 apresenta os 8 sinais recebidos do ECU. As 5 velocidades do motor Diesel (RPM) podem ser observadas na figura 12a. Pode-se, também, relacionar os 9 diferentes *notchs* de potência da locomotiva com o volume de Diesel injetado no motor, quanto maior o volume injetado, maior potência disponibilizada por ele. Na figura 12g é possível notar 9 distintos volumes de injeção. Por volta da amostra 57500 o vazamento foi inserido.

Como era esperado pelo engrenamento existente entre o eixo virabrequim e a bomba d'água, a pressão de saída (figura 12d) relaciona-se diretamente com a velocidade do motor

Figura 11 – Dados Interpolados.



Fonte: Própria

(figura 12a). As variações de pressão da água de menor magnitude, mesmo com o motor com velocidade constante, são causadas pelas variações da temperatura da água (figura 12e).

## 4.2 Resultados via detecção baseada em modelos do processo

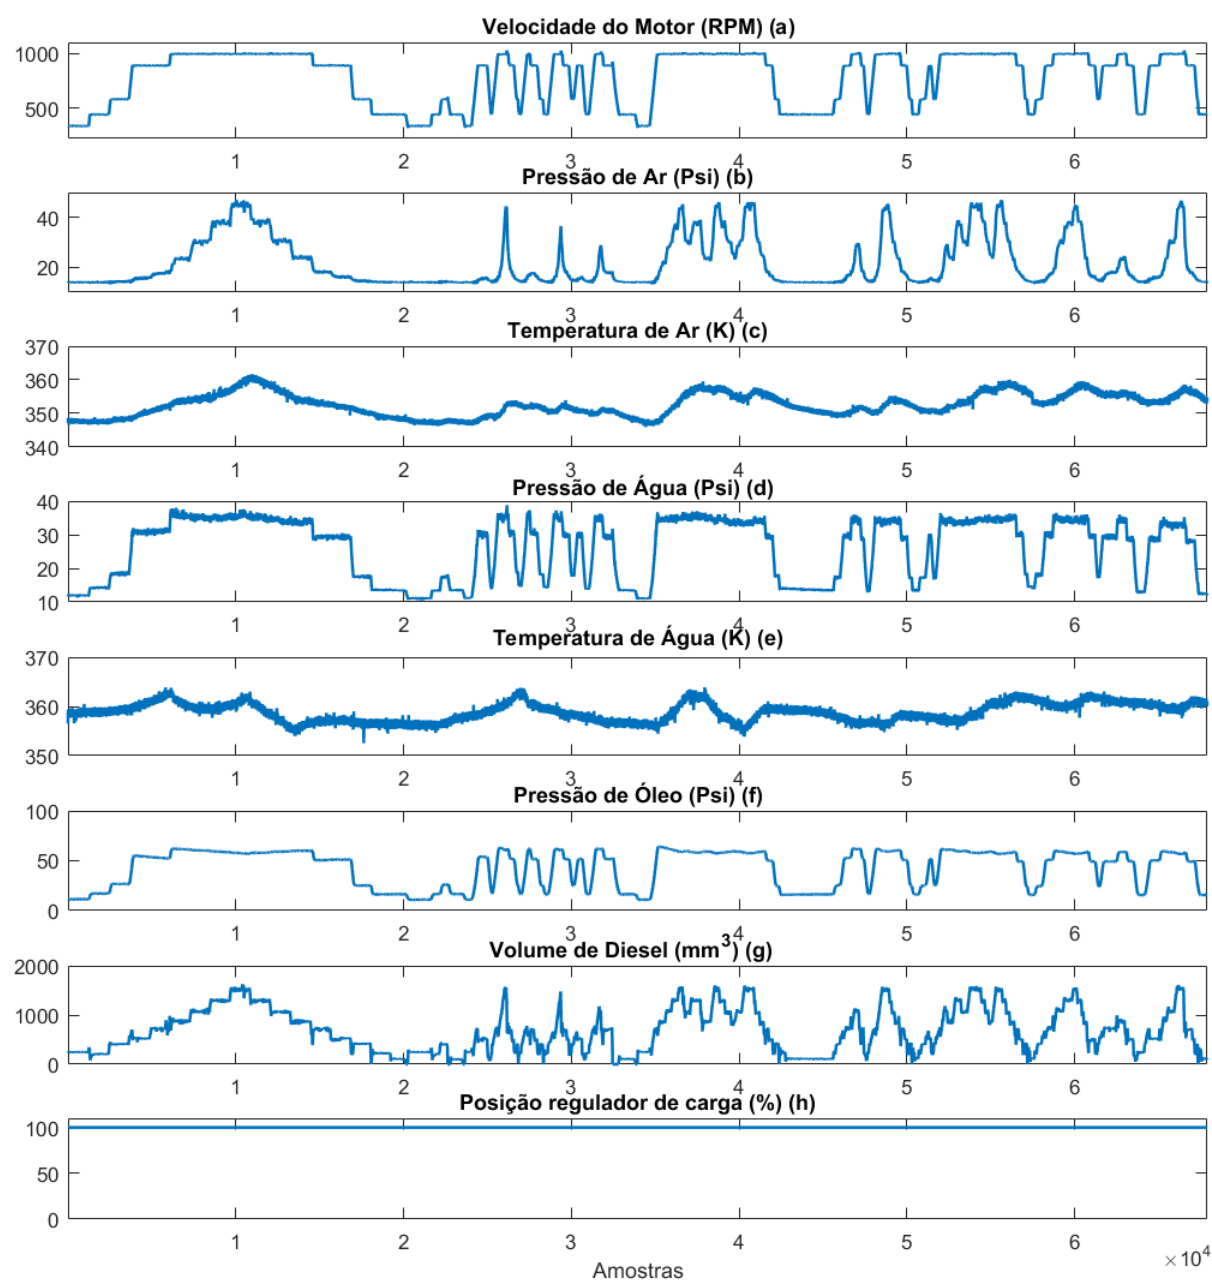
Na seção a seguir são apresentados os resultados da primeira abordagem. É feita a detecção da falha inserida ao sistema de arrefecimento analisando os resíduos gerados pelos modelos, com auxílio de cartas de Shewhart e da carta de soma cumulativa.

### 4.2.1 Detecção dos pontos de operação

Como se deseja detectar as falhas nos momentos em que a velocidade do motor esteja em regime permanente, é necessário que dados das transições dos pontos de operação sejam retirados, fazendo com que os agrupamentos sejam bem definidos. A figura 13 apresenta o gráfico de dispersão entre a pressão e a temperatura com dados de transição da velocidade do motor. Nota-se, visualmente, os 5 possíveis agrupamentos de dados.


O classificador  $kNN$  foi treinado para detectar os pontos de operação e regiões de transição. Foram selecionadas para o treinamento 20000 amostras (amostras 34000 a 54000)

Figura 12 – Sinais coletados em operação normal e com vazamento de água.



Fonte: Própria

Figura 13 – Dispersão de pressão e temperatura sem classificação.



Fonte: Própria

no gráfico superior da figura 14. Essas amostras continham dados de todas as classes que se deseja treinar, 514 amostras para classe de velocidade do motor de 335 RPM, 3686 amostras para 440 RPM, 1435 amostras para 580 RPM, 1911 amostras para 888 RPM, 11142 amostras para 995 RPM e 1312 amostras de transições. As amostras foram rotuladas conforme descrito na seção de metodologia 3.2.1. Usando os dados de validação obteve-se sensibilidade e especificidade de 97.92% dos dados em regime permanente (amostras 12000 a 32000) no gráfico inferior da figura 14.


O classificador identifica a classe da velocidade com atraso, após as transições. Entretanto, dada a grande quantidade de amostras em regime permanente, este erro é desprezível. Na figura 15 são mostrados os dados de validação do classificador, velocidade com os pontos separados das classes (gráfico superior) e a saída do classificador (gráfico inferior). As 6 classes são identificadas e durante as transições a saída do classificador é zero.

Os gráficos de dispersão de temperatura *versus* pressão para cada uma das classes são mostrados na figura 16. Observa-se a existência da relação entre estas variáveis, assim como o agrupamento para cada ponto de operação. Com o aumento da temperatura existe o aumento da pressão interna do sistema de arrefecimento do motor, ou seja, além da velocidade, a pressão varia com a mudança de temperatura, o que é esperado termodinamicamente. Observa-se, também, o aumento da dispersão da pressão com o





Figura 16 – Dados agrupados por ponto de operação.



Fonte: Própria

aumento da velocidade do motor.


#### 4.2.2 Seleção dos modelos

Utilizando a metodologia proposta para cada uma das 4 técnicas de geração dos modelos, para modelos únicos e múltiplos definidos na seção 3.2.2, geraram-se 24 conjuntos com 500 possíveis modelos cada, totalizando 12000 modelos gerados para essa abordagem. Cada conjunto de modelo gerado na validação cruzada *repeated k-fold* foi avaliado individualmente usando o coeficiente de Spearman e erro (RMSE). A figura 17 apresenta o resultado de um conjunto com 500 modelos, onde um deles é selecionado conforme a metodologia.

A figura 18 e a tabela 3 apresentam os modelos obtidos pelas 4 técnicas de modelagem para cada um dos 5 pontos de operação. Os melhores modelos, baseados no coeficiente de Spearman, são indicados por setas. Observa-se que técnicas diferentes obtiveram resultados distintos entre os 5 pontos de operação.


O uso de múltiplos modelos foi então comparado ao uso de um único modelo para todos os pontos de operação. Para cada uma das 4 técnicas de modelagem obteve-se um modelo único e um modelo por ponto de operação. O resultado é mostrado na figura 19. Os resíduos dos 5 modelos foram concatenados para o cálculo do coeficiente de Spearman,

Figura 17 – Comparação entre o coeficiente de Spearman e RMSE para regressão obtida via SVR no ponto de operação de 995 RPM.



Fonte: Própria

Figura 18 – Comparativo entre o coeficiente de Spearman entre todas as técnicas de modelagem por ponto de operação.




Fonte: Própria

Tabela 3 – Tabela comparativa entre o coeficiente de Spearman entre todas as técnicas de modelagem por ponto de operação.

RPM	SVR	TREE	GRNN	POLY
335	79,8%	<b>82,5%</b>	76,9%	79,1%
440	<b>67,8%</b>	67,5%	65,5%	67,7%
580	77,4%	<b>79,0%</b>	76,1%	67,3%
888	77,2%	77,0%	75,0%	<b>78,5%</b>
995	<b>69,9%</b>	69,5%	68,1%	69,8%

Figura 19 – Comparativos entre os coeficientes de Spearman das técnicas empregadas.



Fonte: Própria

de forma que o comprimento do vetor fosse igual ao caso de modelo único. Na figura 20 o mesmo foi feito para a análise do erro.


Na técnica de regressão polinomial verificou-se que não havia melhorias significativas com grau maior que 3. Para a rede neural, buscou-se melhorar os resultados da regressão generalizada variando a suavização, e o valor de 0.2 utilizado gerou os melhores resultados. Valores menores dificultavam muito a convergência do algoritmo de treinamento.

Todas as técnicas apresentaram resultados melhores com o uso de múltiplos modelos, ou seja, melhor coeficiente de Spearman com erros menores dos resíduos. O resultado denominado “Melhores modelos” foi obtido selecionando os modelos que deram melhor resultado por ponto de operação na etapa anterior (figura 18).

#### 4.2.3 Detecção de falhas

Com a utilização do classificador foi possível normalizar os resíduos por ponto de operação, viabilizando a detecção de falha por estatística univariada e analisar os

Figura 20 – Comparativos entre os erros (RMSE) das técnicas empregadas.



Fonte: Própria

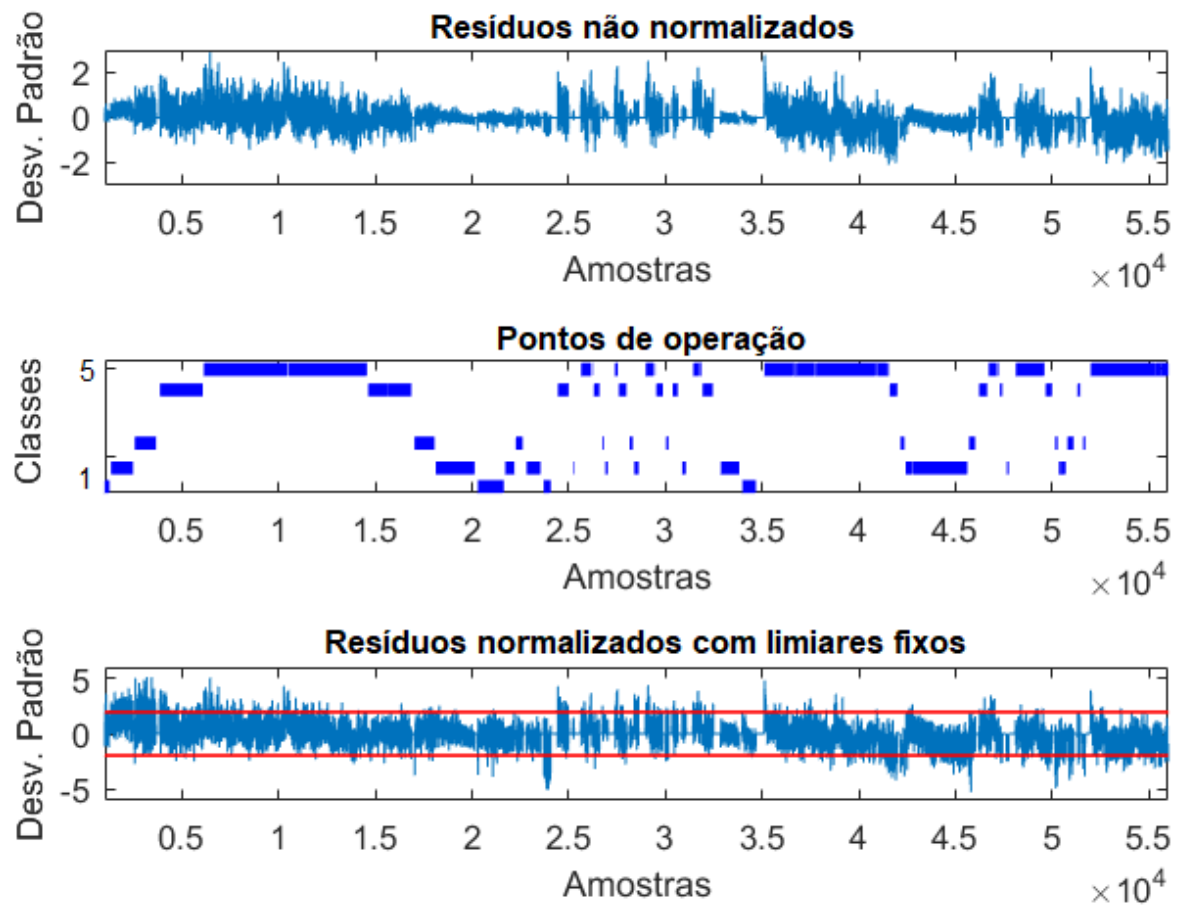
resíduos com limiares estatísticos constantes. A figura 21 apresenta a saída contínua dos resíduos não normalizados e normalizados pelas variâncias de cada ponto de operação, gerados pelos múltiplos modelos (dados concatenados). Fica clara a diferença da variância dos resíduos nos diferentes pontos de operação (velocidades do motor). Portanto, a normalização dos resíduos deve ser diferente em cada região para que se tenha um único limiar estatístico. O uso do classificador para identificar estas regiões torna-se fundamental durante o monitoramento das falhas. Na figura 21 (inferior) os resíduos foram normalizados obedecendo a saída do classificador. O resíduo é zero nos instantes de transição dos pontos de operação do motor. Os limiares do gráfico inferior na mesma figura são calculados com um nível de confiança de 99%.

Da figura 21 (inferior) pode-se concluir que a utilização da carta de controle de Shewhart não fornece bons resultados. Nenhuma das regras de Shewhart para indicar processo fora de controle é atendida, indicando vazamentos com frequência (falsos alarmes).

Obteve-se melhor resultado para a detecção do vazamento com a carta de soma cumulativa. Os limiares inferior de -180 e superior de 180 de desvios-padrão cumulativos foram determinados iterativamente para que não houvesse falsos positivos usando os dados de treinamento.

Como sabe-se da existência do vazamento, era esperado que a falha fosse identificada quando a soma cumulativa ultrapassasse o limiar inferior (figura 22 inferior). O vazamento foi detectado com um atraso de 220s após seu início. Este tempo de detecção é adequado para o problema, pois estima-se que o sistema de proteção do motor levaria uma hora para ser acionado devido a esta falha.

Figura 21 – Resíduos não normalizado e resíduos normalizados com limiares fixos.



Fonte: Própria

É possível verificar pela figura 22 inferior o momento em que o vazamento é detectado na carta de soma cumulativa, não retornando para o centro da carta mesmo após sucessivas mudanças do ponto de operação.


### 4.3 Resultados via classificadores

Nesta seção são apresentados os resultados da segunda abordagem. Uma nova falha foi inserida ao trecho dos dados de operação normal do sistema de arrefecimento. E por meio de classificadores busca-se a detecção e diagnóstico das duas falhas.

#### 4.3.1 Escolha das características

Após os testes de desempenho dos classificadores, que apresentaram bons resultados utilizando as 24 características, todas as características foram avaliadas individualmente de forma visual e aquelas que não apresentavam diferenças claras entre as diferentes classes foram eliminadas. Verificou-se que a assimetria e a sua variação dentro das janelas podiam

Figura 22 – Detecção de Vazamento na Carta de Soma Cumulativa.



Fonte: Própria

ser eliminadas, assim como é observado para a curtose.


A assimetria e a variação da assimetria dos dados de pressão são apresentados na figura 23. Optou-se em retirar essas características do treinamento do classificador, restando ao total 12 características. Os classificadores foram novamente treinados e com este conjunto reduzido de dados não foram observadas mudanças significativas na sua medida de desempenho.

#### 4.3.2 Classificador kNN


A média dos MSE obtido usando o classificador *KNN* é mostrada na figura 24 para 1, 3, 5 e 7 vizinhos e para janelas de tamanho 50, 100 e 200. Tamanhos maiores das janelas produzem um erro menor. Um maior número de vizinhos, no entanto, não contribuiu para diminuir o erro. Uma explicação para esse efeito é uma redução na capacidade de generalização para um número maior de vizinhos.

MSE menores tendem a reduzir o erro de classificação. Este efeito pode ser observado

Figura 23 – Valor da assimetria e sua variação com uma janela de 200 amostras.



Fonte: Própria

Figura 24 – Média dos desempenhos do classificador *KNN*

Fonte: Própria

Figura 25 – Matriz de confusão do classificador kNN, dados de treinamento

<b>k=3</b>	Classe 1	Classe 2	Classe 3	Total	<b>k=7</b>	Classe 1	Classe 2	Classe 3	Total
Classe 1	22589	0	0	22589	Classe 1	22589	0	0	22589
Classe 2	1	6023	0	6024	Classe 2	1	6022	1	6024
Classe 3	0	0	5266	5266	Classe 3	0	0	5266	5266
Total	22590	6023	5266	33879	Total	22590	6022	5267	33879

Fonte: Própria

Figura 26 – Matriz de confusão do classificador kNN, dados de testes

<b>k=3</b>	Classe 1	Classe 2	Classe 3	Total	<b>k=7</b>	Classe 1	Classe 2	Classe 3	Total
Classe 1	22583	112	0	22695	Classe 1	22580	113	2	22695
Classe 2	0	5949	105	6054	Classe 2	0	5943	111	6054
Classe 3	0	0	5205	5205	Classe 3	1	4	5200	5205
Total	22583	6061	5310	33954	Total	22581	6060	5313	33954

Fonte: Própria

comparando o MSE médio (figura 24) com a matriz de confusão calculada para os dados de treinamento (figura 25). Usando  $k = 5$  produziu um menor MSE e também um menor número de erros de classificação.


A matriz de confusão também foi calculada para os dados de testes para  $k = 3$  e  $k = 7$  e é mostrada na Figura 26. O número de erros é muito pequeno também neste caso, com 217 erros para  $k = 5$  e 231 erros para  $k = 7$ , num total de aproximadamente 34000 amostras.



### 4.3.3 Classificador ANN

A rede neural artificial foi treinada para janelas de tamanho 50, 100, 200 e para 2, 5, 10, 20 neurônios na primeira camada oculta. O desempenho médio medido dos MSE dos classificadores é mostrado na figura 27

Figura 27 – Comparativo das médias dos desempenhos das redes neurais



Fonte: Própria

Claramente, o aumento do tamanho da janela e do número de neurônios, contribui para reduzir o erro. A matriz de confusão foi calculada usando o conjunto de dados de treinamento e é mostrada na figura 28. É possível observar que a redução do número de neurônios aumenta o número de erros de classificação.

Usando os dados de testes, a matriz de confusão para 20 e 5 neurônios na primeira camada oculta com uma janela de tamanho 200 foi calculada e é mostrada na Figura 29. Os resultados continuam mostrando o efeito de reduzir o número de neurônios no número de erros de classificação.

O número de erros de classificação usando kNN para  $k = 3$  e ANN para 20 neurônios, ambas com janelas de tamanho 200, foi muito semelhante. O número semelhante de erros da classe 2 previstos como classe 1 e classe 3 previstos como classe 2 deve-se a características calculadas usando dados durante a transição de tais classes, uma vez que os dados das três classes foram produzidos sequencialmente.

Figura 28 – Matriz de confusão do classificador ANN, dados de treinamento

Número de Neurônios 20	Classe 1	Classe 2	Classe 3	Total	Número de Neurônios 5	Classe 1	Classe 2	Classe 3	Total
Classe 1	22589	0	0	22589	Classe 1	22542	0	47	22589
Classe 2	0	6024	0	6024	Classe 2	7	5764	253	6024
Classe 3	0	1	5265	5266	Classe 3	196	256	4814	5266
Total	22589	6025	5265	33879	Total	22745	6020	5114	33879


Fonte: Própria

Figura 29 – Matriz de confusão do classificador ANN, dados de testes

Número de Neurônios 20	Classe 1	Classe 2	Classe 3	Total	Número de Neurônios 5	Classe 1	Classe 2	Classe 3	Total
Classe 1	22583	112	0	22695	Classe 1	22516	128	51	22695
Classe 2	0	5949	105	6054	Classe 2	221	5722	111	6054
Classe 3	0	0	5205	5205	Classe 3	64	170	4971	5205
Total	22583	6061	5310	33954	Total	22801	6020	5133	33954

Fonte: Própria

Figura 30 – Aplicação online do classificador: classes esperadas e as indicadas



Fonte: Própria

#### 4.3.4 Aplicação online

Uma aplicação online desta proposta também foi testada, usando o classificador kNN (figura 30). Neste teste, todos os dados coletados foram utilizados como entrada para o classificador. Há um atraso de cerca de 200 amostras para que uma falha seja detectada. Como as falhas detectadas levam muito tempo para causar danos, os 10 segundos necessários para a detecção são insignificantes. Outro importante ponto a ser observado é que mesmo com as sucessivas mudanças de ponto de operação (figura 30 superior) o classificador não comete erros de classificações após o fim das transições das classes.

### 4.4 Comparação entre as abordagens

Pelos resultados obtidos é possível fazer a comparação do emprego das duas abordagens na tarefa de detecção do vazamento da água, uma vez que a primeira abordagem não faz detecção da falha da redução da pressão no circuito da água. A primeira abordagem é capaz de detectar a falha apenas com dados de normalidade, enquanto a segunda requer também dados de falha. O desempenho neste caso pode ser comparado medindo o tempo

para a detecção da falha. A segunda abordagem detecta a falha em aproximadamente 10 segundos, enquanto que a primeira abordagem requereu aproximadamente 220 segundos. Para o motor Diesel ferroviário, ambos os tempos são plenamente satisfatórios, pois o sistema de proteção do motor o desligaria em um tempo superior a 1h para o vazamento introduzido. A segunda abordagem é mais simples, requer apenas a disponibilização de características rotuladas. A primeira requer o treinamento do classificador e adicionalmente a obtenção de modelos para cada ponto de operação.

## 5 Conclusões

O motor Diesel é o principal meio de geração de energia das composições ferroviárias. Detectar e diagnosticar falhas permite reduzir impactos econômicos decorrentes de custo para sua manutenção e para reboque em caso de pane. Os motores Diesel dependem de vários subsistemas para sua operação sem falhas, sendo tratado neste trabalho o sistema de arrefecimento. Para isso, foram apresentadas duas metodologias: a detecção de falhas baseada em modelos do processo e a detecção de falhas usando classificadores, ambas baseadas em dados fornecidos pelo sistema de controle do motor.

Na primeira abordagem os dados permitiram identificar características das variáveis sensíveis às falhas, bem como o efeito de diferentes velocidades do motor sobre as mesmas. Diferentes modelos foram utilizados para gerar estimativas da pressão do sistema de arrefecimento, que comparadas aos valores medidos, geraram resíduos usados para a detecção da falha. Um classificador kNN foi utilizado para identificar os pontos de operação do motor uma vez que os modelos e os resíduos eram afetados pelos pontos de operação. A partir da coleta de três conjuntos de dados o classificador e os modelos foram treinados, validados e testados. Essa metodologia permitiu detectar o vazamento de água antes que pudesse causar problemas no sistema de arrefecimento. Nesta abordagem, apenas esta falha foi detectada. O atraso na detecção decorre do ajuste do limiar usado na carta de soma cumulativa para evitar falsos positivos. Um único modelo poderia ser usado para todos os pontos de operação, mas a normalização do resíduo nestes pontos é necessária, requerendo um classificador. Um único classificador foi treinado para detectar os pontos de operação, dada a facilidade de sua separação. Vários modelos foram testados para gerar os resíduos, tendo sido escolhido o melhor para cada ponto de operação.

Na segunda abordagem dois classificadores, kNN e rede neural artificial, foram utilizados para detecção e diagnóstico de duas falhas. Foram extraídas características dos sinais de velocidade do motor, pressão e temperatura da água de arrefecimento. Os dois classificadores foram treinados para diagnosticar falhas de vazamento de água e de redução de pressão no circuito de água e arrefecimento. Os classificadores mostraram desempenhos semelhantes medidos pelo erro quadrático médio e pelo erro de classificação. Os resultados foram bons, se considerados a sua precisão e tempo de resposta. Os diferentes pontos de operação foram tratados naturalmente pelos dois classificadores, sem afetar seu desempenho. O tamanho da janela para cálculo das características foi variado. No caso de método kNN variou-se o número de vizinhos, e para o ANN o número de neurônios da camada oculta. Isso permitiu fazer as escolhas dos parâmetros que deram o melhor desempenho sem gerar esforços computacionais exagerados.

Sugere-se para trabalhos futuros:

- Aumentar o número de falhas detectadas;
- Fazer o diagnóstico de falhas na primeira abordagem usando os resíduos;
- Modelar fisicamente os sistemas do motor Diesel, melhorando condições de detecção e diagnóstico de falhas;
- Testar outras técnicas de validação de modelos, buscando evitar polarização;
- Escrever os algoritmos de detecção e diagnóstico em linguagem *Python* e embarcar nas locomotivas;
- Usar os diagnósticos para atuar sobre o sistema de controle do motor;
- Avaliar o uso do sistema de diagnóstico desenvolvido em outras locomotivas sem a necessidade de novos treinamentos.

# Referências

AHMED, R. et al. Automotive internal-combustion-engine fault detection and classification using artificial neural network techniques. *IEEE Transactions on vehicular technology*, IEEE, v. 64, n. 1, p. 21–33, 2015. Citado na página 35.

ALPTEKIN, E. Emission, injection and combustion characteristics of biodiesel and oxygenated fuel blends in a common rail diesel engine. *Energy*, Elsevier, v. 119, p. 44–52, 2017. Citado na página 22.

ANTORY, D. et al. Fault diagnosis in internal combustion engines using non-linear multivariate statistics. *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering*, SAGE Publications Sage UK: London, England, v. 219, n. 4, p. 243–258, 2005. Citado na página 34.

AZEVEDO, C. R.; JR, E. H. Análise de falhas de implantes cirúrgicos no brasil: a necessidade de uma regulamentação adequada. *Cadernos de Saúde Pública*, SciELO Public Health, v. 18, p. 1347–1358, 2002. Citado na página 41.

BASSHUYSEN, R. V.; SCHÄFER, F. *Internal combustion engine handbook-basics, components, systems and perspectives*. [S.l.: s.n.], 2004. v. 345. Citado 3 vezes nas páginas 19, 22 e 25.

BISWAS, R. K.; MASUD, M. S.; KABIR, E. Shewhart control chart for individual measurement: an application in a weaving mill. In: AUSTRALIAN ACADEMY OF BUSINESS LEADERSHIP. *Proceedings of the 2015 Melbourne International Business and Social Science Research Conference*. [S.l.], 2015. Citado na página 39.

BOULKROUNE, B.; AITOUICHE, A.; COCQUEMPOT, V. Actuator fault detection and isolation for diesel engines. In: IEEE. *Control Applications (CCA), 2013 IEEE International Conference on*. [S.l.], 2013. p. 78–84. Citado na página 32.

CECCARELLI, R. et al. Model-based adaptive observers for intake leakage detection in diesel engines. In: IEEE. *American Control Conference, 2009. ACC'09*. [S.l.], 2009. p. 1128–1133. Citado na página 30.

CHARCHALIS, A.; DERESZEWSKI, M. Processing of instantaneous angular speed signal for detection of a diesel engine failure. *Mathematical Problems in Engineering*, Hindawi, v. 2013, 2013. Citado na página 29.

CHEN, J.; PATTON, R. J. *Robust model-based fault diagnosis for dynamic systems*. [S.l.]: Springer Science & Business Media, 2012. v. 3. Citado 2 vezes nas páginas 29 e 32.

CHEN, J. et al. Artificial neural network based fault diagnosis of ic engines. In: TRANS TECH PUBL. *Key Engineering Materials*. [S.l.], 2012. v. 518, p. 47–56. Citado na página 35.

CHIANG, L. H.; RUSSELL, E. L.; BRAATZ, R. D. *Fault detection and diagnosis in industrial systems*. [S.l.]: Springer Science & Business Media, 2000. Citado 2 vezes nas páginas 31 e 34.

- CURZON, F.; AHLBORN, B. Efficiency of a carnot engine at maximum power output. *American Journal of Physics*, AAPT, v. 43, n. 1, p. 22–24, 1975. Citado na página 20.
- DING, S. X. *Model-based fault diagnosis techniques: design schemes, algorithms, and tools*. [S.l.]: Springer Science & Business Media, 2008. Citado na página 29.
- DUIN, R. P.; TAX, D. M. Classifier conditional posterior probabilities. In: SPRINGER. *Joint IAPR International Workshops on Statistical Techniques in Pattern Recognition (SPR) and Structural and Syntactic Pattern Recognition (SSPR)*. [S.l.], 1998. p. 611–619. Citado na página 41.
- EMD, E. M. D. *EMD Locomotive*. [S.l.: s.n.], 2010. Citado na página 15.
- FLETT, J.; BONE, G. M. Fault detection and diagnosis of diesel engine valve trains. *Mechanical systems and signal processing*, Elsevier, v. 72, p. 316–327, 2016. Citado na página 35.
- FTOUTOU, E.; CHOUCANE, M. Injection fault detection of a diesel engine by vibration analysis. In: SPRINGER. *International Conference Design and Modeling of Mechanical Systems*. [S.l.], 2017. p. 11–20. Citado na página 29.
- GERTLER, J. Fault detection and diagnosis in engineering systems. *CRC, Virginia, USA*, 1998. Citado na página 31.
- GIL-PITA, R.; YAO, X. Evolving edited k-nearest neighbor classifiers. *International Journal of Neural Systems*, World Scientific, v. 18, n. 06, p. 459–467, 2008. Citado na página 41.
- GUZZELLA, L.; ONDER, C. *Introduction to modeling and control of internal combustion engine systems*. [S.l.]: Springer Science & Business Media, 2009. Citado na página 22.
- HÄMÄLÄINEN, W.; VINNI, M. Classifiers for educational data mining. *Handbook of Educational Data Mining, Chapman & Hall/CRC Data Mining and Knowledge Discovery Series*, p. 57–71, 2011. Citado na página 34.
- HE, Q. P.; WANG, J. Statistics pattern analysis: A new process monitoring framework and its application to semiconductor batch processes. *AIChE journal*, Wiley Online Library, v. 57, n. 1, p. 107–121, 2011. Citado na página 34.
- ISERMANN, R. Model-based fault-detection and diagnosis—status and applications. *Annual Reviews in control*, Elsevier, v. 29, n. 1, p. 71–85, 2005. Citado 3 vezes nas páginas 29, 30 e 32.
- ISERMANN, R. *Combustion engine diagnosis*. [S.l.]: Springer, 2016. Citado 6 vezes nas páginas 17, 28, 29, 31, 32 e 33.
- JOHNSON, K. G.; MOLLENHAUER, K.; TSCHÖKE, H. *Handbook of diesel engines*. [S.l.]: Springer Science & Business Media, 2010. Citado na página 14.
- JOHNSSON, R. *Crankshaft speed measurements and analysis for control and diagnostics of diesel engines*. Tese (Doutorado) — Luleå tekniska universitet, 2001. Citado na página 29.



- KHELIL, Y. et al. Fault detection and isolation in marine diesel engines: A generic methodology. *IFAC Proceedings Volumes*, Elsevier, v. 45, n. 20, p. 964–969, 2012. Citado 2 vezes nas páginas 17 e 31.
- KIMMICH, F.; SCHWARTE, A.; ISERMANN, R. Fault detection for modern diesel engines using signal-and process model-based methods. *Control Engineering Practice*, Elsevier, v. 13, n. 2, p. 189–203, 2005. Citado 2 vezes nas páginas 17 e 33.
- KISIĆ, E. et al. Fault detection in electric power systems based on control charts. *Serbian Journal of Electrical Engineering*, v. 10, n. 1, p. 73–90, 2013. Citado na página 39.
- KUHN, M.; JOHNSON, K. *Applied predictive modeling*. [S.l.]: Springer, 2013. v. 26. Citado na página 39.
- LEE, J.; KAO, H.-A.; YANG, S. Service innovation and smart analytics for industry 4.0 and big data environment. *Procedia Cirp*, Elsevier, v. 16, p. 3–8, 2014. Citado na página 15.
- LI, L.; WU, Z. An on-line fault diagnosis method for gas engine using ap clustering. In: IEEE. *Autonomous Decentralized System (ISADS), 2017 IEEE 13th International Symposium on*. [S.l.], 2017. p. 149–155. Citado na página 34.
- LIU, C.-L.; SAKO, H.; FUJISAWA, H. Performance evaluation of pattern classifiers for handwritten character recognition. *International Journal on Document Analysis and Recognition*, Springer, v. 4, n. 3, p. 191–204, 2002. Citado na página 41.
- LIU, J.; YAO, A.; YAO, C. Effects of diesel injection pressure on the performance and emissions of a hd common-rail diesel engine fueled with diesel/methanol dual fuel. *Fuel*, Elsevier, v. 140, p. 192–200, 2015. Citado na página 22.
- LIU, R. et al. Artificial intelligence for fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, Elsevier, v. 108, p. 33–47, 2018. Citado 2 vezes nas páginas 35 e 40.
- MAGDI, K. K.; JÄÄSKELÄINEN, H. *Diesel Fuel Injection*. DieselNet Technology Guide, 2013. Disponível em: <[https://www.dieselnet.com/tech/diesel\\_fi.php#types](https://www.dieselnet.com/tech/diesel_fi.php#types)>. Citado na página 21.
- NEELAMEGAM, S.; RAMARAJ, E. Classification algorithm in data mining: An overview. *International Journal of P2P Network Trends and Technology (IJPTT)*, v. 4, n. 8, p. 369–374, 2013. Citado na página 34.
- NYBERG, C. M. *Model Based Fault Diagnosis: Methods, Theory, and Automotive Engine Applications, PhDthesis*. Tese (Doutorado), 1999. Citado 2 vezes nas páginas 17 e 33.
- PATAN, K. *Artificial neural networks for the modelling and fault diagnosis of technical processes*. [S.l.]: Springer, 2008. Citado 4 vezes nas páginas 28, 30, 31 e 33.
- PATEL, B. N.; PRAJAPATI, S. G.; LAKHTARIA, K. I. Efficient classification of data using decision tree. *Bonfring International Journal of Data Mining*, Bonfring, v. 2, n. 1, p. 6, 2012. Citado na página 34.


- RAWSON, W. *5 Most Common Causes of Cooling System Failure*. 2016. Disponível em: <<http://www.radiatorrepair.com/5-most-common-causes-of-cooling-system-failure/>>. Citado na página 24.
- REED, M. *Cooling System Failures Engine Power De-Rating: Dangerous for Soldiers, Burdens on Missions, and Avoidable. Evans Waterless Coolant*. 2015. Disponível em: <<https://www.linkedin.com/pulse/cooling-system-failures-engine-power-de-rating-dangerous-matthew-reed>>. Citado na página 24.
- REFAEILZADEH, P.; TANG, L.; LIU, H. Cross-validation. In: *Encyclopedia of database systems*. [S.l.]: Springer, 2009. p. 532–538. Citado na página 39.
- REIF, K. *Diesel engine management*. [S.l.]: Springer, 2014. Citado 2 vezes nas páginas 20 e 21.
- SCHWARTE, A.; ISERMANN, R. *Model-based fault detection of diesel intake with common production sensors*. [S.l.], 2002. Citado 2 vezes nas páginas 17 e 31.
- SERVICE, D. A. R. *5 Signs of Cooling System Failure*. 2013. Disponível em: <<https://www.dauidsautorepairservice.com/blog/5-signs-of-cooling-system-failure>>. Citado na página 24.
- SHATNAWI, Y.; AL-KHASSAWENEH, M. Fault diagnosis in internal combustion engines using extension neural network. *IEEE Transactions on Industrial Electronics*, IEEE, v. 61, n. 3, p. 1434–1443, 2014. Citado na página 35.
- VERSMOLD, H.; SAEGER, M. et al. Plausibility checking of sensor signals for vehicle dynamics control systems. In: CITESEER. *8th International Symposium on Advanced Vehicle Control AVEC Taiwan*. [S.l.], 2006. Citado na página 28.
- WANG, G.; LIU, J.; LI, Y. Fault diagnosis using knn reconstruction on mri variables. *Journal of Chemometrics*, Wiley Online Library, v. 29, n. 7, p. 399–410, 2015. Citado na página 34.
- WANG, X. et al. Nonlinear pca with the local approach for diesel engine fault detection and diagnosis. *IEEE Transactions on Control Systems Technology*, IEEE, v. 16, n. 1, p. 122–129, 2008. Citado na página 34.
- XIN, Q. *Diesel engine system design*. [S.l.]: Elsevier, 2011. Citado na página 20.
- YANG, J. et al. Fault detection in a diesel engine by analysing the instantaneous angular speed. *Mechanical systems and signal processing*, Elsevier, v. 15, n. 3, p. 549–564, 2001. Citado na página 29.
- ZHANG, H. et al. Sample data synchronization and harmonic analysis algorithm based on radial basis function interpolation. *Mathematical Problems in Engineering*, Hindawi, v. 2014, 2014. Citado na página 36.

## APÊNDICE A – Circuito eletrônico de coleta

Grande parte das plataformas de desenvolvimento operam em níveis lógicos usualmente TTL de 0 a 3.3V ou 0 a 5V, com isso deve existir preocupação quanto ao nível de tensão usada entre os dispositivos. Neste caso utiliza-se o padrão RS232 onde as tensões podem ir de  $\pm 3V$  a  $\pm 18V$  e com isso é necessário um circuito eletrônico que converta sinais RS232 para TTL de 3.3V.

O circuito de conversão de padrão de comunicação é bastante simples. Hoje no mercado brasileiro é facilmente encontrado o circuito integrado MAX232, porém esse permite somente nível de tensão TTL de 5V. Para que seja possível utilizar a plataforma escolhida é preciso utilizar o circuito integrado MAX3232, esse permite a utilização do nível de tensão TTL de 3.3V. A figura 31 apresenta o conversor desenvolvido para a aplicação. Ele tem capacidade para ser alimentado pela própria fonte dos computadores da locomotiva e receber dados de todos os computadores da locomotiva que comunicam-se por RS232. Dessa maneira é possível embarcar o sistema de detecção e diagnóstico na locomotiva. Com o circuito instalado na locomotiva é possível além do controle do motor Diesel, receber e enviar dados aos computadores de controle da parte elétrica.

Figura 31 – Conversor RS232 para TTL 3.3V.



Fonte:Própria

## APÊNDICE B – Código MATLAB para coleta de dados

```

1  clc
2  clear all
3  close all
4
5  %% Configurando Comunicacao com o EGU
6
7  s=serial('COM1','BaudRate',9600,'Parity','even','FlowControl','software','
    DataBits',7,'Terminator',13,'ReadAsyncMode','continuous');
8
9  %% Enderecos (Maximo 8 enderecos);
10 %%00094304
11 endereco='00094304 000940D0 000940CE 000940C8 000940CA 000940CC 0009431C
    00094310';
12
13
14 %% Escrevendo para o EGU
15 caracteres=length(endereco);
16 fopen(s);
17 fwrite(s,25);
18 pause(0.1);
19 fwrite(s,'M');
20 pause(0.1);
21 fwrite(s,'M');
22
23 for i=1:1:caracteres
24     pause(0.1);
25     charac=endereco(1,i);
26     fwrite(s,charac)
27     %%if i==(8|16 && 24|32 && 40|48 && 56|64)
28         %%pause(0.1);
29         %%fwrite(s,20)
30     %%end
31 end
32 pause(0.1);
33 fwrite(s,13)
34
35 %% Recebendo dados do EGU
36 c=0;
37 for i=1:1:600
38 out=fscanf(s);

```

```
39 data=char(out);
40
41 if length(data)==73
42
43 Engine_Speed=(sscanf(data(1,1:4), '%x'))/16;
44 Manifold_air_pressure=(sscanf(data(1,10:13), '%x'))/128;
45 Manifold_air_temperature=(sscanf(data(1,19:22), '%x'))/64;
46 Coolant_pressure=(sscanf(data(1,28:31), '%x'))/128;
47 Coolant_temperature=(sscanf(data(1,37:40), '%x'))/64;
48 Lube_Oil_Pressure=(sscanf(data(1,46:49), '%x'))/128;
49 Fuel_Value=(sscanf(data(1,55:58), '%x'))/8;
50 Load_Pot=(sscanf(data(1,64:67), '%x'))/32*1023;
51
52 Vetor_dados(i,1:8)=[Engine_Speed Manifold_air_pressure
    Manifold_air_temperature Coolant_pressure Coolant_temperature
    Lube_Oil_Pressure Fuel_Value Advance_angle];
53
54 Consumo(1,i)=(Engine_Speed)*(Fuel_Value)*0.00048;
55 end
56 end
57 fclose(s)
```

# APÊNDICE C – Código Python para coleta de dados

```

1
2 import numpy as np
3 import serial
4 import sys
5 import glob
6 import time
7
8
9 arquivo=input("Inserir nome de arquivo ") #Nome do arquivo a ser gravado
10
11 serEGU = serial.Serial(port = "COM7", baudrate=9600,bytesize=7,parity='E',
12     stopbits=1) #Configuracao serial para comunicar com o EGU
13 serEGU.close()
14
15 endereco='00094304 000940D0 000940CE 000940C8 000940CA 000940CC 0009431C
16     0009431E' #Endereco solicitados ao EGU
17
18 ##Solicitacoes ao EGU
19 caracteres=len(endereco)
20 serEGU.open()
21 time.sleep(1)
22 serEGU.write(25)
23 time.sleep(1) #Tempo necessario para nao gerar conflito de comunicacao com
24     o EGU
25 serEGU.write('M'.encode())
26 time.sleep(0.01)
27 serEGU.write('M'.encode())
28 time.sleep(0.01)
29 serEGU.write(' '.encode())
30 time.sleep(0.01)
31
32 count = 1
33 while count < caracteres+1:
34     time.sleep(0.01)
35     charpEGU=endereco[count-1:count]
36     serEGU.write(charpEGU.encode())
37     #print(charpEGU)
38     count += 1
39     time.sleep(0.01)
40
41

```

```

38 serEGU.write('\r'.encode())
39
40 ##Fim da solicitacoes e inicio do recebimento dos dados
41
42 Tmp=time.clock()
43 count=0
44 Saida_total=[0,0,0,0,0,0,0,0,0]
45
46 while Tmp < 20: #Quantidade de dados desejados.
47     SaidaEGU = serEGU.read_until(terminator='\r'.encode())
48     Tmp=time.clock()
49     # print(SaidaEGU)
50     SaidaEGU==str(SaidaEGU, 'utf-8')
51     #SaidaEGU="000041A0 00003E30 000041A0 000041A0 000041A0 000041A0 000041A0 000041A0" Exemplo de saida
52     # Exemplo de dados recebidos pelo EGU = SaidaEGU abaixo, pega-se os
ultimo 2 bytes de cada palavra e faz a conversao
53     # OBS: Cada variavel que foi lida tem um denominador diferente ex(16 ou
64... etc), olhar configuracoes do EGU para verificar qual o divisor.
54     if (count>20):
55         ES = float((int(SaidaEGU[0:4],16)))/16 #Engine_Speed
56         MP= float((int(SaidaEGU[9:13],16)))/128 #Manifold_air_pressure
57         MK = float((int(SaidaEGU[18:22],16)))/64 #Manifold_air_temperature
58         CP = float((int(SaidaEGU[27:31],16)))/128 #Coolant_pressure
59         CK = float((int(SaidaEGU[36:40],16)))/64 #Coolant_temperature
60         OP = float((int(SaidaEGU[45:49],16)))/128 #Lube_Oil_Pressure
61         FV = float((int(SaidaEGU[54:58],16)))/8 #Fuel_Value
62         LP = float((int(SaidaEGU[63:67],16)))/(32*1023) #Load Potentiometer
63         Saida_tratada=[Tmp,ES,MP,MK,CP,CK,OP,FV,LP]
64         print(Saida_tratada)
65         Saida_tratada=np.array([Tmp,ES,MP,MK,CP,CK,OP,FV,LP])
66         Saida_total=np.vstack((Saida_total,Saida_tratada))
67     count=count+1
68
69 serEGU.close()
70
71 np.savetxt(arquivo,Saida_total, delimiter=",")

```